



**Universidad
Zaragoza**

Trabajo Fin de Máster

Estimación de la respuesta fisiológica en
entornos hiperbáricos mediante modelado
computacional basado en redes neuronales
artificiales

Autor/es

Cristina Pérez Martínez

Director/es

Carlos Sánchez Tapia

Ponente

Eduardo Gil Herrando

Escuela de Ingeniería y Arquitectura
Universidad de Zaragoza
2019

Agradecimientos

Gracias a la gente del CUD, sobre todo a mi director Carlos Sánchez por descubrirme nuevos campos de investigación biomédica y por su implicación diaria en este trabajo.

Mención especial a mi familia, así como a mis amigos/as de Murcia y, sin ser menos importantes, a las personas de Zaragoza que me han acompañado en esta etapa: compañeros/as, profesores/as, el grupo ADR y, sobre todo, a las de la “columna izquierda”.



DECLARACIÓN DE AUTORÍA Y ORIGINALIDAD

(Este documento debe acompañar al Trabajo Fin de Grado (TFG)/Trabajo Fin de Máster (TFM) cuando sea depositado para su evaluación).

TRABAJOS DE FIN DE GRADO / FIN DE MÁSTER

D./D^a. _____,

con nº de DNI _____ en aplicación de lo dispuesto en el art.

14 (Derechos de autor) del Acuerdo de 11 de septiembre de 2014, del Consejo de Gobierno, por el que se aprueba el Reglamento de los TFG y TFM de la Universidad de Zaragoza,

Declaro que el presente Trabajo de Fin de (Grado/Máster)
_____, (Título del Trabajo)

es de mi autoría y es original, no habiéndose utilizado fuente sin ser citada debidamente.

Zaragoza, _____

Fdo: _____

Estimación de la respuesta fisiológica en entornos hiperbáricos mediante modelado computacional basado en redes neuronales artificiales

RESUMEN

El buceo es una actividad que, hoy en día, se practica tanto como hobby como de forma profesional. Durante la inmersión, el cuerpo experimenta cambios biológicos y fisiológicos. De modo que, según la ley de Poiseuille, para mantener una adecuada respuesta cardíaca y minimizar los efectos de los cambios de la presión hidrostática se produce un descenso de la frecuencia cardíaca.

Teniendo en cuenta que la variabilidad del ritmo cardíaco (HRV) es considerada una medida no invasiva de la regulación del Sistema Nervioso Autónomo (SNA) sobre el corazón, se cuenta con una base de datos compuesta por parámetros temporales y frecuenciales (*índices*), calculados a partir de la grabación de la señal del ECG de sujetos sometidos a ambientes que simulan la inmersión, hasta 40 m, en una cámara hiperbárica. Para potenciar la base de datos, se añaden ciertas variables biofísicas extraídas de la información aportada por los sujetos en las pruebas.

El objetivo central de este trabajo fin de máster es tratar de predecir, previamente a la inmersión, el valor que tomarían los índices a 40 m de profundidad con la idea de evitar una posible situación de riesgo para la salud del sujeto. En la primera parte de este trabajo se recoge el estudio de las relaciones entre pares de variables en diferentes etapas de la inmersión, empleando la regresión lineal y el método de *Mutual Information* para analizar tanto relaciones lineales como no lineales.

Con el fin de modelar las relaciones entre índices, variables biofísicas, profundidad de inmersión y sujetos, en la segunda parte del trabajo se utilizan redes neuronales artificiales. Concretamente, se emplean *mapas auto-organizados* (SOM) para detectar de forma visual esas posibles relaciones. Para finalizar, usando los índices registrados en la primera etapa del proceso donde el sujeto se encuentra a nivel del mar (1 atm) junto a ciertas variables biofísicas como parámetros de entrada, se lleva a cabo el entrenamiento de redes neuronales de tipo perceptrón (MLP), y se analizan las características obtenidas al emplear diferentes arquitecturas y algoritmos de entrenamiento para escoger así la mejor red que sea capaz de predecir cada índice cuando el sujeto se encuentra a 40 m de profundidad.

Estimation of the physiological response in hyperbaric environments using computational modelling based on neural networks

ABSTRACT

Diving is currently one of the most demanding sport activities, either as a recreational practice or as a professional practice. Human body is affected by different factors in the aquatic environment that entail biological and physiological changes. According to Poiseuille's law, a decrease in the heart rate is needed to maintain an adequate cardiac output and to minimise the effects of hydrostatic pressure.

Heart Rate Variability signal (HRV) is considered a non-invasive technique to measure Autonomic Nervous System (ANS) activity. Temporal and frequency parameters (*indices*) were calculated using electrocardiogram (ECG) signals, which were recorded to subjects inside a hyperbaric chamber simulating an immersion of 40 m. Moreover, biophysical information of each subject was added to the database.

The main aim of this work is to predict the values of the parameters extracted from the ECG signal when a diver is at a depth of 40 m, with the purpose of preventing any risk for the health of the subject. The first part of the work is focused on modelling the relationship between two variables: parameters which were recorded at different stages (simulating different depths) and the biophysical ones. Both linear and nonlinear dependences were analysed by using linear regression and Mutual Information techniques.

In the second part, relationships between parameters of HRV signals, biophysical variables, atmospheric pressure changes (at different depths) and subjects are analysed using Artificial Neural Networks (ANN). Specifically, self-organizing maps (SOM) were calculated to detect these relationships visually. Finally, the estimation of HRV indices at 40 m was performed using multilayer perceptrons (MLPs), in which the parameters of HRV signal recorded at sea level (1 atm) and some biophysical variables were taken as inputs. Different MLPs were calculated changing the architecture and the training algorithm in order to find the best MLP to predict each parameter of HRV signal at 40 m depth.

Índice general

1. Introducción	1
1.1. Antecedentes y motivación	1
1.2. Objetivos	3
1.3. Contenidos de la memoria	3
2. Relación entre variables	5
2.1. Base de datos	5
2.1.1. Índices temporales y frecuenciales	5
2.1.2. Variables biofísicas	6
2.2. Regresión lineal	7
2.2.1. Estudio entre los índices de cada etapa	7
2.2.2. Estudio entre las variables biofísicas y los índices de cada etapa	7
2.3. Mutual Information	10
2.3.1. Entropía	10
2.3.2. Overview sobre Mutual Information	10
2.3.3. Análisis práctico	12
3. Mapas auto-organizados	17
3.1. Mapas auto-organizados de los índices y las etapas	18
3.2. Análisis SOM usando los datos de los índices	19
3.2.1. Caso de estudio 1: Los índices como características	19
3.2.2. Caso de estudio 2: Las etapas como características	20
3.2.3. Caso de estudio 3: Los índices como características, pero se etiquetan sujetos	21
3.3. Análisis SOM usando los datos de los índices y las variables biofísicas	22

4. Redes Neuronales Artificiales Multicapa	25
4.1. Introducción	25
4.1.1. Función de activación y tratamiento de los datos	26
4.1.2. Función de coste y entrenamiento	26
4.2. MLPs para predecir los índices de la etapa 40 según los índices de la etapa 0I	27
4.3. MLPs para predecir los índices de la etapa 40 según los parámetros biofísicos	28
4.4. MLPs para predecir los índices de la etapa 40 utilizando una combinación de entradas	29
5. Discusión	33
6. Conclusiones y trabajo futuro	37
Bibliografía	42
Anexos	
A. Regresión lineal	
A.1. Índices etapa 0I con resto de etapas	
A.2. Índices etapa 0I con variables biofísicas	
B. Mutual Information	
B.1. Índices etapa 0I con resto de etapas	
B.2. Índices etapa 0I con variables biofísicas	
C. Resultados SOM variables biofísicas	
D. Resultados MLP	
D.1. Error medio de cada arquitectura	
D.2. Pesos de las neuronas de entrada de las arquitecturas seleccionadas .	

Capítulo 1

Introducción

1.1. Antecedentes y motivación

El cuerpo humano no se adapta fácilmente a las nuevas condiciones ambientales dadas bajo el agua, por ejemplo, debido a los efectos que se producen biológica, psicológica y fisiológicamente, a causa de periodos de tiempo prolongados en un ambiente hiperbárico. Hoy en día aproximadamente 7 millones de personas practican buceo como hobby y existen muy pocos estudios sobre este campo. De forma general, la distancia máxima de descenso para recrear una inmersión es de 40 metros, aunque algunos profesionales, como científicos o militares, pueden alcanzar profundidades superiores. Teniendo en cuenta que el agua es casi 800 veces más densa que el aire, un descenso de 10 metros implica el incremento en 1 atm de la presión, por lo que personas no profesionales llegan a estar sometidas a 5 atm de presión [4].

Los buceadores están afectados por diferentes factores en el ambiente acuático [5], como una menor visibilidad, una menor temperatura o una mayor presión hidrostática. Según la ley de Poiseuille, para mantener una adecuada respuesta cardíaca y minimizar los efectos de los cambios de la presión hidrostática se produce un descenso de la frecuencia cardíaca [6]. Otro factor a tener en cuenta es la expansión o compresión de gases del interior del cuerpo, ya que puede causar alteraciones mecánicas importantes. Un incremento de la presión parcial de estos gases puede desencadenar una intoxicación bioquímica, tanto de CO_2 , N (narcosis) como de O_2 (hiperoxia), y debido a ello se pueden generar burbujas que provoquen el síndrome de la descompresión rápida (*decompression sickness*, DS), que causa desde alteraciones menores en la piel hasta trastornos neurológicos, cardiopulmonares y del oído interno [7]. Los estudios epidemiológicos han mostrado un aumento de la incidencia del DS y de otros incidentes negativos en la práctica de buceo en las últimas décadas. Como se puede deducir, muchos factores, como la profundidad, la presión o la temperatura, afectan a la respuesta cardiovascular durante la inmersión [8].

La adaptación de la respuesta cardiovascular se refleja en cambios en la presión sanguínea debido al papel del Sistema Nervioso Autónomo (SNA) para mantener la homeostasis en un proceso de inmersión. Las dos ramas principales que forman este sistema son el sistema nervioso simpático y el sistema nervioso parasimpático, o vagal. El balance de activación de estas dos ramas refleja el esfuerzo del cuerpo por adaptarse a las nuevas condiciones de un entorno [9]. Una técnica no invasiva para medir el comportamiento del SNA es por medio de la señal de variabilidad del ritmo cardíaco (*Heart Rate Variability*, HRV), extraída del electrocardiograma (ECG). El análisis espectral de esta señal revela dos bandas principales: una banda de baja frecuencia (*Low-frequency*, LF)[0,04 - 0,15Hz], que refleja el comportamiento tanto de la rama simpática como parasimpática del SNA, y la banda de alta frecuencia (*High-frequency*, HF)[0,15 - 0,4Hz], utilizada como medida de la actividad de la rama parasimpática. Otra señal interesante que se debe considerar en un estudio hiperbárico es la señal respiratoria [10],[11], que se puede extraer también del ECG. Un cambio en la señal respiratoria altera el contenido espectral de la señal HRV y, como consecuencia, la interpretación de las activaciones de los sistemas simpático y vagal [12],[13].




Fig. 1.1. Detección del pulso cardíaco en una señal de ECG y medición del intervalo pico a pico (RR o NN) para extraer la señal de HRV [1].




Fig. 1.2. Señal HRV (izquierda) y su representación en forma de densidad espectral de potencial (derecha), indicando las bandas de frecuencia estudiadas, LF y HF [2].

La respuesta del SNA ha sido analizada en algunos estudios simulando las condiciones de la presión del entorno en el interior de una cámara hiperbárica, sin necesidad de realizar una inmersión real para ello. Los resultados de esos estudios muestran un incremento de la banda de potencia de HF, es decir, se produce un aumento de la actividad parasimpática [14],[15],[16],[17]. Otra conclusión extraída es una reducción del ritmo cardíaco [14],[16],[18],[19], aunque este hecho no es apoyado de forma unánime [17]. En realidad, existen pocos estudios del SNA durante la inmersión, probablemente debido a la dificultad de recoger datos en esas condiciones. En una actividad de inmersión real, a pesar de la existencia de factores externos incontrolables, como el reflejo a la inmersión o el estímulo de la temperatura del agua [20],[21], que puedan derivar en un incremento de la actividad simpática, la respuesta del SNA obtenida refleja el mismo comportamiento que el observado en la cámara hiperbárica: un incremento de la potencia en la banda de HF [22],[23]. Este patrón de comportamiento se puede atribuir al aumento de la sensibilidad de los barorreceptores, que conlleva un incremento en la actividad de la rama parasimpática [24]. Todos estos estudios se caracterizan por una pequeña colección de sujetos (entre 8 y 12), el uso de la señal HRV para estudiar el comportamiento del SNA y el registro de los datos solo entre dos profundidades (entre 2,5 y 3 atm comúnmente).

1.2. Objetivos

Con el objetivo de incrementar la seguridad de los buceadores, se pretende elaborar un modelo matemático (red neuronal multicapa) que sea capaz de estimar el comportamiento fisiológico en entornos hiperbáricos partiendo de determinadas variables extraídas de la señal HRV, así como de otros parámetros biofísicos aportados por los sujetos del estudio. Debido a la abundante cantidad de variables, se realiza un estudio previo de las mismas, empleando técnicas estadísticas, como la *regresión lineal* o *mutual information*, y redes neuronales artificiales, *mapas auto-organizados*, para eliminar aquellas que no sean relevantes y con la posibilidad de detectar cómo influyen estas en los diferentes sujetos. El fin último sería ayudar a la detección de comportamientos anómalos del SNA en condiciones de reposo que no aconsejen la inmersión.

1.3. Contenidos de la memoria

El estudio recogido en esta memoria se organiza en los siguientes puntos:

- En el capítulo 2 se presentan los datos con los que se trabaja, así como un primer análisis dos a dos de las variables en las que se catalogan dichos datos.
- Tras un análisis numérico, en el capítulo 3 se utilizan redes neuronales sencillas

del tipo mapa auto-organizado, con el objetivo de analizar de forma visual los parámetros seleccionados en el apartado anterior y de detectar posibles agrupaciones de sujetos.

- En el capítulo 4 se lleva a cabo el entrenamiento de una red neuronal multicapa, quedando justificadas las variables de entrada por los capítulos anteriores.
- Se discute en el capítulo 5 los resultados de las distintas redes neuronales multicapa, así como las relaciones observadas en los capítulos previos, contrastando esta información con otros artículos.
- Finalmente, en el capítulo 6 se recogen las conclusiones de todo el estudio, junto a las posibles líneas futuras de trabajo.

Capítulo 2

Relación entre variables

2.1. Base de datos

La base de datos está compuesta por las señales de HRV de 31 sujetos de entre 20 y 44 años de edad, predominada por varones, de los cuales 14 fueron descartados por problemas de registro o señales de baja calidad, asignándole un valor de *Not a Number* (NaN) a los índices de la mayoría de etapas de dichos sujetos. El protocolo de actuación se realizó dentro de una cámara hiperbárica, tuvo una duración de 2 horas, aproximadamente, y los estados simulados para los que se grabaron los datos fueron:

- Registro de datos a 1 atm (nivel del mar), *etapa 0I*.
- Simulación de descenso de 20 metros hasta alcanzar 3 atm, *etapa 20I*.
- Simulación de descenso de 40 metros de profundidad hasta alcanzar 5 atm, *etapa 40*.
- Simulación de ascenso mediante una descompresión lenta volviendo a 3 atm, *etapa 20F*.
- Finalización de la simulación hasta alcanzar de nuevo 1 atm, *etapa 0F*.

Partiendo del artículo en el que se basa este trabajo de fin de máster [25], en este estudio se han empleado ocho parámetros extraídos de las señales ECG (temporales) y HRV (frecuenciales), descritos en el apartado 2.1.1, además de otros datos biofísicos correspondientes a cada sujeto, presentados en el apartado 2.1.2.

2.1.1. Índices temporales y frecuenciales

Los cuatro parámetros temporales se han calculado por medio de medidas entre dos picos de pulsos consecutivos de una serie temporal del ECG [13]:

- $NN(s)$: Valor mediano de los intervalos entre latidos consecutivos clasificados como Normales (NN).
- $SDNN(s)$: Rango intercuartílico de los intervalos NN, como una medida de dispersión estadística.
- $RMSSD(s)$: Raíz cuadrada de la media de los cuadrados de las diferencias sucesivas entre los intervalos NN adyacentes.
- $pNN50(\%)$: Número de pares de NN sucesivos que difieren en más de 50ms, dividido por el número total de intervalos NN.

De forma similar, pero usando la densidad espectral de potencia de la señal HRV, calculada como Hernando et al. [13], se obtienen los siguientes cuatro parámetros frecuenciales:

- $PLF(ad)$: Potencia en la banda de baja frecuencia de la señal HRV.
- $PHF(ad)$: Potencia en la banda de alta frecuencia de la señal HRV.
- $PLFn(nu)$: Potencia en la banda de baja frecuencia normalizada de la señal HRV:

$$PLFn = \frac{PLF}{PLF + PHF}$$

- $RLFHF(nu)$: Ratio entre la potencia en la banda de baja frecuencia y de alta frecuencia:

$$RLFHF = \frac{PLF}{PHF}$$

Este conjunto de 8 parámetros será referido como *índices* a lo largo de la memoria, de modo que se cuenta con valores de esos 8 índices para cada uno de los 5 estados de profundidad o *etapas*.

2.1.2. Variables biofísicas

Se cuenta con información relacionada con los parámetros biofísicos de los sujetos que participaron, por lo que se estudia si estos resultan útiles para la estimación de la respuesta fisiológica del SNA. Los parámetros biofísicos extraídos son: *Edad*, *Género*, *Altura*, *Peso*, presión arterial alta y baja (*PAalta* y *PAbaja*), pulsaciones (*Puls.*), si está tomando medicación (*Medic.*), si sufre dolor (*Dolor*), parámetros relacionados con la menstruación, si es fumador (*Fuma*), si toma alcohol (*Alcohol*) o/y otras sustancias, si toma cafeína (*Cafeína*), si consume bebidas gaseosas (*B. gas*), si ha consumido algo de lo anterior durante las últimas 4 horas (*Últ.4h*), si practica deporte, si hace submarinismo (*Submar.*), si duerme 8 horas o más (*D. 8h+*), y si lo pasa mal en espacios cerrados. Esta lista de parámetros queda más

reducida al eliminar las variables relacionadas con la *menstruación*, debido a la baja participación de sujetos femeninos y a la no diversidad en las respuestas, y las variables de *consumo de otras sustancias* y *si lo pasa mal en espacios cerrados*, ya que todas las respuestas fueron negativas. Así la variable *si practica deporte* también queda descartada porque los sujetos con respuesta negativa no están en la lista de seleccionados para este trabajo.

No se llegan a seleccionar aquellos parámetros cuya respuesta es altamente subjetiva, como el nivel de salud, si ha sufrido ansiedad, su estado de tranquilidad antes de la prueba, si tiene sueño reparador, etc.

2.2. Regresión lineal

Se escoge la regresión lineal como un primer modelo matemático para analizar la dependencia lineal entre dos variables de cada una de las etapas. El motivo de elegir esta técnica estadística es por la facilidad de interpretación de los resultados. De modo que se analiza el valor cuadrático del coeficiente de correlación de Pearson, R^2 , tomando como relación lineal significativa aquellos valores por encima de 0,75. Se trabaja con los datos originales tanto de los índices extraídos del SNA como de los parámetros biofísicos.

2.2.1. Estudio entre los índices de cada etapa

Se analiza el resultado de la regresión lineal entre una variable en la *etapa 0I* con el resto de las variables de las distintas etapas, reflejado en las tablas 2.1 y 2.2 (junto a las tablas A.1, A.2 y A.3 del Anexo A), y se puede deducir que:

- Las variables temporales NN y RMSSD de la *etapa 0I* están relacionadas linealmente con las variables NN y RMSSD de todas las etapas.
- Se dan casos puntuales y minoritarios de relaciones lineales entre los índices en la *etapa 0I* y los índices en otras etapas, como sucede entre los índices temporales pNN50 de la *etapa 0I* con las *etapas 20I y 20F*, y entre los índices frecuenciales PHF de la *etapa 0I* con las *etapas 20I y 20F*.

2.2.2. Estudio entre las variables biofísicas y los índices de cada etapa

Según los valores del coeficiente R^2 entre las variables biofísicas y los índices en cada etapa de las tablas 2.3 y 2.4, y las recogidas en el Anexo A (tablas A.4, A.5, A.6), se concluye que:

- Existe relación lineal entre las *pulsaciones* y los índices NN y RMSSD en todas las etapas, lo cual es, en cierto modo, esperable.
- En la *etapa 40* se tienen dos relaciones lineales interesantes: el índice PLF se relaciona con los datos de *si el paciente toma medicación* y *si consume cafeína*. Es decir, ambas ramas del SNA estarían afectadas por estos dos factores a alta presión. Por otro lado, en esta misma etapa, la variable *Submarinismo* no se ha tenido en cuenta puesto que los valores recogidos en algunos sujetos eran de tipo *NaN*, obteniendo mediciones estadísticas no fiables para el cálculo de R^2 .
- En la *etapa 0F* aparece una relación lineal entre el parámetro *si el paciente sufre dolor* y el índice SDNN, aunque su interpretación fisiológica es complicada ya que el dolor no se especifica de qué tipo es.

		Etapa 0I							
		NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Etapa 0I	NN	1,000	0,416	0,997	0,540	0,240	0,007	0,048	0,036
	SDNN	0,416	1,000	0,437	0,834	0,040	0,275	0,131	0,054
	RMSSD	0,997	0,437	1,000	0,564	0,237	0,003	0,059	0,044
	pNN50	0,540	0,834	0,564	1,000	0,001	0,306	0,328	0,224
	PLF	0,240	0,040	0,237	0,001	1,000	0,191	0,050	0,069
	PHF	0,007	0,275	0,003	0,306	0,191	1,000	0,491	0,294
	PLFn	0,048	0,131	0,059	0,328	0,050	0,491	1,000	0,803
	RLFHF	0,036	0,054	0,044	0,224	0,069	0,294	0,803	1,000

Tabla 2.1. Valores de R^2 entre los índices del estado 0I y del estado 0I.

		Etapa 40							
		NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Etapa 0I	NN	0,829	0,144	0,873	0,239	0,177	0,042	0,009	0,068
	SDNN	0,388	0,467	0,491	0,491	0,004	0,111	0,020	0,008
	RMSSD	0,824	0,149	0,873	0,249	0,181	0,036	0,011	0,069
	pNN50	0,523	0,462	0,633	0,623	0,009	0,106	0,072	0,073
	PLF	0,224	0,166	0,151	0,008	0,457	0,219	0,037	0,269
	PHF	0,005	0,195	0,015	0,350	0,189	0,633	0,113	0,040
	PLFn	0,189	0,040	0,178	0,397	0,003	0,211	0,257	0,332
	RLFHF	0,144	0,106	0,141	0,411	0,000	0,211	0,197	0,326

Tabla 2.2. Valores de R^2 entre los índices del estado 0I y del estado 40.

Etapa 0I								
	NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Edad	0,000	0,166	0,000	0,096	0,311	0,142	0,035	0,037
Género	0,215	0,058	0,221	0,074	0,011	0,047	0,026	0,032
Altura	0,176	0,109	0,174	0,150	0,016	0,000	0,000	0,004
Peso	0,143	0,139	0,147	0,218	0,013	0,015	0,021	0,012
PAalta	0,140	0,143	0,148	0,170	0,001	0,084	0,060	0,027
PAbaja	0,001	0,001	0,002	0,012	0,067	0,012	0,000	0,008
Puls.	0,879	0,566	0,871	0,611	0,733	0,139	0,061	0,061
Medic.	0,132	0,008	0,144	0,023	0,137	0,194	0,013	0,028
Dolor	0,381	0,232	0,385	0,217	0,012	0,006	0,001	0,012
Fuma	0,090	0,220	0,087	0,233	0,008	0,131	0,012	0,000
Alcohol	0,001	0,010	0,001	0,010	0,000	0,048	0,073	0,069
Cafeína	0,168	0,011	0,168	0,067	0,142	0,042	0,031	0,074
B. gas	0,004	0,008	0,001	0,072	0,020	0,150	0,169	0,289
Últ.4h	0,006	0,006	0,009	0,011	0,071	0,063	0,329	0,105
Submar.	0,001	0,001	0,002	0,033	0,012	0,064	0,215	0,508
D. 8h+	0,007	0,044	0,011	0,060	0,022	0,029	0,007	0,043

Tabla 2.3. Valores de R^2 entre los datos biofísicos y las variables del estado 0I.

Etapa 40								
	NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Edad	0,000	0,273	0,007	0,110	0,167	0,294	0,003	0,026
Género	0,287	0,037	0,330	0,154	0,206	0,012	0,017	0,001
Altura	0,157	0,088	0,192	0,082	0,000	0,023	0,027	0,069
Peso	0,166	0,151	0,235	0,184	0,080	0,000	0,014	0,001
PAalta	0,220	0,283	0,297	0,467	0,577	0,003	0,285	0,066
PAbaja	0,002	0,074	0,002	0,373	0,233	0,294	0,611	0,186
Pulsac.	0,971	0,224	0,954	0,364	0,329	0,022	0,011	0,242
Medic.	0,146	0,004	0,162	0,023	0,766	0,166	0,064	0,049
Dolor	0,309	0,272	0,332	0,039	0,001	0,022	0,068	0,041
Fuma	0,101	0,126	0,126	0,080	0,000	0,087	0,113	0,110
Alcohol	0,022	0,058	0,010	0,009	0,016	0,043	0,001	0,000
Cafeína	0,146	0,004	0,162	0,023	0,766	0,166	0,064	0,049
B. gas	0,001	0,353	0,002	0,241	0,154	0,162	0,009	0,037
Últ.4h	0,030	0,072	0,018	0,006	0,107	0,001	0,153	0,162
D. 8h+	0,113	0,240	0,163	0,236	0,006	0,145	0,061	0,020

Tabla 2.4. Valores de R^2 entre los datos biofísicos y las variables del estado 40.

2.3. Mutual Information

La regresión lineal tiene la limitación de que busca relaciones lineales entre los pares de variables, pero no se puede descartar a priori que dichas parejas estén relacionadas de forma no lineal. Por ello se recurre al cálculo del parámetro de *Mutual Information*, el cual se basa en los valores de entropía de las variables analizadas, como se explica a continuación.

2.3.1. Entropía

La entropía de una variable aleatoria es una función que trata de caracterizar lo impredecible que es esta variable, dando información tanto del número de posibles resultados como de la frecuencia de estos [26]. Matemáticamente, la cantidad promedio de información que transmite una variable aleatoria en un proceso, es decir, la entropía de una variable aleatoria x se define como:

$$H(x) = - \sum (p(x) \cdot \log_2(p(x)))$$

donde el signo negativo asegura que la información es positiva o cero, y $p(x)$ es la distribución de probabilidad. Así que una baja probabilidad de x indica un alto contenido de información. $H(x)$ se mide en bits (“binary digits”).

Propiedades de entropía:

- No negativa: $H(x) \geq 0$.
- $H(x) = 0$ si y solo si x es determinista.

2.3.2. Overview sobre Mutual Information

Se trata de un método no paramétrico basado en la estimación de la entropía para cuantificar la información compartida entre dos variables, x e y , por ejemplo, independientemente de que sea lineal o no. *Mutual Information*, MI , o también representada como $I(x, y)$, utiliza para su cálculo distribuciones de probabilidad (individuales y conjuntas), y, de forma análoga, se puede utilizar valores de entropías (condicionales y conjuntas):

$$I(x, y) = \sum_{x, y} \left(p(x, y) \cdot \log \left(\frac{p(x, y)}{p(x) \cdot p(y)} \right) \right)$$

$$I(x, y) = H(x) + H(y) - H(x, y) = H(x) - H(x|y) = H(y) - H(y|x)$$

Donde:

- $H(x, y)$ es lo que se conoce como *joint entropy*, que mide cuánta incertidumbre hay en dos variables aleatorias, es decir, cuánto de independientes son entre ellas.
- $H(x|y)$ es la *condicional entropy*, una medida de cuánta incertidumbre existe sobre x cuando se conoce el valor de y .
- $p(x, y)$ es la distribución de probabilidad conjunta: $p(x, y) = p(x) \cdot p(y)$.




Fig. 2.1. Diferentes valores de entropía. Mutual information es la incertidumbre común en ambas variables, x e y [3].

En otras palabras, MI da información sobre cuánto dice una variable aleatoria sobre la otra. Se trata de una cantidad adimensional. Un alto valor de $I(x, y)$ indica una gran reducción de la incertidumbre, es decir, se puede predecir con precisión el valor de una variable conociendo la otra. Por el contrario, si se tiene un valor bajo de $I(x, y)$, por mucho conocimiento que se tenga de una de las variables, no ayuda a predecir la otra. Si x e y son estadísticamente independientes, x no contiene información de y , y viceversa, de modo que $I(x, y) = 0$. Desafortunadamente, la información aportada por MI no indica la relación entre las variables, pues un alto valor puede estar asociado tanto a una relación lineal como no lineal.

Propiedades Mutual Information

- $I(x, y) = 0$ si las variables son independientes [27].
- El valor de MI siempre es mayor o igual a cero, es decir, es no negativa, y el valor máximo que puede alcanzar es el de la entropía de cada variable: $0 \leq I(x, y) \leq \min(H(x), H(y))$.

2.3.3. Análisis práctico

Para calcular el valor de MI se usa la función optimizada aportada por Jose Delpino [28] modificada ligeramente al añadir la expresión de *mutual information normalizada* (*nMI*) [3]. Teniendo en cuenta que solo acepta valores de entrada enteros, se realiza un mapeo previo, exigiendo la detección de pares de valores válidos para el cálculo de la entropía conjunta de ambas variables. El valor normalizado obtenido se localiza en el intervalo $[0,1]$.

Se trabaja con los valores originales tanto de los índices medidos del SNA como de los parámetros biofísicos y, en ambos casos, se toma el punto de 0,75 a partir del cual se considera que la variable en el estado 0I aporta cierto grado de información sobre uno de los parámetros. Se escoge este valor para seguir la misma filosofía tomada en la regresión lineal.

Estudio entre los índices de cada etapa

Según los resultados recogidos en las tablas 2.5 y 2.6, junto a las del Anexo B, se aprecia que existe correlación entre la variable NN del estado 0I y los índices NN y RMSSD, salvo para el segundo índice mencionado en la *etapa 20F*. El mayor valor de nMI se da entre el índice NN de la *etapa 0I* y el índice RMSSD de la *etapa 20F*.

De igual forma, existe correlación entre el índice RMSSD de la *etapa 0I* con ese mismo índice y con la variable NN, salvo en las *etapas 20I y 40*. Estos últimos resultados contrastan con lo expuesto anteriormente en la regresión lineal; por lo que el coeficiente de correlación no es suficiente para saber si las variables de estudio están correlacionadas, ya que asume que la relación entre las dos variables que se analizan es lineal. El valor de Mutual Information indica, sin embargo, cómo de posible es realizar un buen modelo con esas variables [29].

Por último, se observa que aparecen relaciones no lineales en las *etapas 20I, 40 y 0F*, destacando los valores positivos entre la variable pNN50 de la *etapa 0I* con los índices NN, pNN50, PLFN y RLFHF en la *etapa 40*, el índice PLF de la *etapa 0I* con los parámetros NN, RMSSD, pNN50, PLF y PHF de la *etapa 0F*, así como el índice PHF de la *etapa 0I* con las variables NN, RMSSD, pNN50 y PHF de la *etapa 0F*.

		Etapa 0I							
Etapa 0I		NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
	NN	1,000	0,617	0,884	0,604	0,639	0,623	0,586	0,422
	SDNN	0,617	1,000	0,564	0,691	0,625	0,625	0,647	0,529
	RMSSD	0,884	0,564	1,000	0,552	0,569	0,670	0,575	0,501
	pNN50	0,604	0,691	0,552	1,000	0,569	0,569	0,617	0,547
	PLF	0,639	0,625	0,569	0,569	1,000	0,588	0,609	0,518
	PHF	0,623	0,625	0,670	0,569	0,588	1,000	0,679	0,471
	PLFn	0,586	0,647	0,575	0,617	0,609	0,679	1,000	0,712
	RLFHF	0,422	0,529	0,501	0,547	0,518	0,471	0,712	1,000

Tabla 2.5. Valores de MI normalizados entre los índices del estado 0I y del estado 0I.

		Etapa 40							
Etapa 0I		NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
	NN	0,788	0,712	0,705	0,738	0,785	0,601	0,758	0,594
	SDNN	0,658	0,696	0,557	0,724	0,568	0,636	0,692	0,627
	RMSSD	0,775	0,699	0,690	0,778	0,707	0,585	0,746	0,577
	pNN50	0,753	0,732	0,663	0,758	0,616	0,678	0,779	0,754
	PLF	0,702	0,682	0,603	0,655	0,616	0,682	0,679	0,611
	PHF	0,658	0,753	0,494	0,669	0,568	0,698	0,747	0,565
	PLFn	0,725	0,649	0,631	0,677	0,580	0,585	0,700	0,576
	RLFHF	0,623	0,666	0,575	0,579	0,374	0,526	0,606	0,449

Tabla 2.6. Valores de MI normalizados entre los índices del estado 0I y del estado 40.

Estudio entre las variables biofísicas y los índices de cada etapa

Las correlaciones entre las variables biofísicas y los índices se localizan casi siempre entre las mismas parejas en las 5 etapas, según los resultados de las tablas 2.7, 2.8 y del Anexo B. A simple vista, destacan los resultados positivos para las variables biofísicas *presión arterial alta (PAalta)* y *pulsaciones (Puls.)*, aunque no se consiguen valores significativos con el índices PHF en ninguna de las etapas de ascenso para ambas variables. Se extrae que el valor de la presión arterial influye sobre las variables NN y pNN50 a 1 atm, mientras que este parámetro biofísico se relaciona con el índice SDNN al aumentar la presión; y con el índice RLFHF a 5 atm. En cuanto a *Puls.*, en la *etapa 40* gran parte de los valores registrados son la unidad, de modo que no se pueden aceptar estas relaciones debido a las pocas muestras válidas con las que se realiza el análisis.

Por otro lado, las variables *Edad*, *altura* y *presión arterial baja (PAbaja)* presentan relaciones positivas puntuales. Concretamente, para *PAbaja* se obtienen valores bajos (por debajo de 0,4) en los índices pNN50 y RLFHF de la *etapa 20I*, y en SDNN en la *etapa 0F*.

Para el resto de parámetros biofísicos, los valores de nMI se consideran bajos (entre 0,1 y 0,4), pero se destacan los siguientes cambios:

- Se puede decir que la variable *si toma medicación (Medic.)* tiene cierta influencia sobre las variables frecuenciales, mayoritariamente, ya que se observan relaciones donde nMI es mayor de 0,4.
- En cuanto al parámetro *si fuma (Fuma)* se destaca el leve ascenso del valor de nMI con el índice pNN50 para las *etapas 0I*, *20I* y *40*.
- Por el contrario, el parámetro *si toma alcohol (Alcohol)* presenta un valor de relación muy bajo (menos de 0,1) con el índice PHF de la *etapa 0I*.
- *Si ha tomado alguna de las sustancias mencionadas en las últimas 4 horas (Últ.4h)* experimenta valores de relación no lineal por encima de 0,4 con el índice PLFn en las *etapas 0I*, *40*, *20F* y *0F*; mientras que con el índice PHF este aumento solo se localiza en las etapas de ascenso.
- Respecto a *si practica submarinismo (Submar.)*, en la etapa 40 se obtiene que es totalmente independiente de todos los índices. Obtener justo un valor 0 se debe a las pocas muestras válidas para el cálculo de nMI.
- Por último, el parámetro *si ha dormido más de 8 horas (D.8h+)* destaca cómo su relación con el índice pNN50 es muy baja en la *etapa 0I*, pero en la *etapa 20I* sufre un gran ascenso. Así mismo, con el índice PLF tiene una mayor relación en la *etapa 0F*, frente al valor muy bajo calculado en las *etapas 20I* y *40*.

Es importante notar que no todos los parámetros pueden ser estimados correctamente en todas las etapas (ya sea por fallos de registro o mala calidad de las señales). Como se ha comentado previamente, en estos casos, al parámetro se le asigna el valor NaN para la etapa y el sujeto en estudio, y no se tiene en cuenta en las mediciones estadísticas generales mostradas en las tablas.

Con el fin de modelar las relaciones entre índices, variables biofísicas, etapas y sujetos vistas, a lo largo de los siguientes capítulos se utilizan redes neuronales artificiales.

Etapa 0I								
	NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Edad	0,604	0,606	0,593	0,552	0,670	0,527	0,575	0,518
Género	0,193	0,167	0,194	0,144	0,231	0,411	0,124	0,221
Altura	0,574	0,591	0,562	0,562	0,580	0,624	0,759	0,557
Peso	0,552	0,509	0,540	0,624	0,515	0,558	0,606	0,597
PAalta	0,769	0,651	0,712	0,769	0,603	0,782	0,836	0,634
PAbaja	0,675	0,510	0,596	0,675	0,440	0,453	0,646	0,508
Puls.	1,000	0,626	1,000	0,821	0,767	0,872	0,715	0,715
Medic.	0,216	0,115	0,220	0,356	0,356	0,372	0,368	0,237
Dolor	0,341	0,224	0,344	0,224	0,170	0,139	0,144	0,106
Fuma	0,172	0,216	0,123	0,402	0,342	0,146	0,176	0,191
Alcohol	0,132	0,156	0,104	0,340	0,282	0,091	0,276	0,202
Cafeína	0,198	0,237	0,200	0,370	0,377	0,257	0,321	0,280
B. gas	0,325	0,298	0,327	0,159	0,170	0,429	0,335	0,227
Últ.4h	0,283	0,154	0,370	0,146	0,199	0,377	0,495	0,256
Submar.	0,167	0,100	0,168	0,215	0,171	0,171	0,343	0,374
D. 8h+	0,400	0,171	0,403	0,167	0,257	0,220	0,181	0,256

Tabla 2.7. Valores de MI normalizados entre los datos biofísicos y las variables del estado 0I.

Etapa 40								
	NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Edad	0,649	0,685	0,553	0,712	0,564	0,568	0,786	0,620
Género	0,249	0,273	0,225	0,419	0,237	0,176	0,302	0,200
Altura	0,609	0,649	0,568	0,677	0,450	0,585	0,700	0,514
Peso	0,665	0,647	0,652	0,731	0,578	0,521	0,699	0,659
PAalta	0,558	0,892	0,558	0,726	0,607	0,744	0,726	0,833
PAbaja	0,618	0,805	0,618	0,621	0,673	0,618	0,805	0,751
Puls.	1,000	0,866	1,000	1,000	1,000	0,866	1,000	1,000
Medic.	0,176	0,171	0,190	0,222	0,431	0,248	0,165	0,249
Dolor	0,410	0,381	0,419	0,377	0,196	0,116	0,219	0,429
Fuma	0,303	0,429	0,281	0,456	0,131	0,211	0,355	0,406
Alcohol	0,363	0,309	0,207	0,460	0,105	0,156	0,298	0,180
Cafeína	0,176	0,171	0,190	0,222	0,431	0,248	0,165	0,249
B. gas	0,492	0,322	0,307	0,361	0,358	0,287	0,345	0,121
Últ.4h	0,287	0,240	0,189	0,312	0,203	0,143	0,407	0,165
Submar.	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
D. 8h+	0,363	0,469	0,287	0,346	0,138	0,283	0,298	0,309

Tabla 2.8. Valores de MI normalizados entre los datos biofísicos y las variables del estado 40.

Capítulo 3

Mapas auto-organizados

Un Mapa auto-organizado, SOM, es una red neuronal artificial compuesta por neuronas organizadas en una cuadrícula regular, generalmente hexagonal. Cada neurona tiene un peso asociado a cada entrada, de forma que al final del entrenamiento contará con un vector de pesos, siendo este similar entre neuronas vecinas [30]. En este trabajo, se calculan SOMs con el fin de detectar de forma visual posibles relaciones entre variables, aparte de las encontradas en el Capítulo 2, que permitan reducir el número de variables de entrada de los modelos.

Se realiza un **entrenamiento por defecto**, donde la inicialización del proceso de entrenamiento se hace de forma aleatoria, y, por defecto, es lineal; se usa un algoritmo de entrenamiento por lotes. Un parámetro interesante del mapa obtenido es el denominado *best matching units* (BMU), que indica las neuronas de la red cuyos vectores de pesos se parecen más a un vector de datos de entrada. En la práctica, esta similitud se mide como la mínima distancia euclídea entre ambos vectores.

Los mapas tienen dos propiedades principales que indican la **calidad del mapa auto-organizado** generado [31]:

- La precisión de representación de los datos (*mean quantization error*).
- La precisión en la representación de la topología del conjunto de datos (*topographic error*).

Nota: Es preferible que ambas medidas de calidad no sean exactamente cero.[31]

La primera propiedad se mide normalmente usando el error de cuantificación promedio entre los vectores de datos y sus BMUs del mapa. Para la segunda se han propuesto varias medidas, por ejemplo, la medida del error topográfico, que consiste en calcular el tanto por ciento de los vectores de datos para los cuales la primera y la segunda BMUs no son unidades adyacentes.

3.1. Mapas auto-organizados de los índices y las etapas

Debido a que los datos de entrada para entrenar un SOM deben estar entre el intervalo $[0,1]$, y para evitar la influencia de lo mayor o menor que es un valor en sí, se decide normalizar los índices de las etapas según el valor registrado en la línea de base (*etapa 0I*):

$$\frac{\text{Valor en una etapa}}{\text{Valor en una etapa} + \text{Valor en la etapa } 0I}$$

En cuanto al número de neuronas, se establece un tamaño de 7x7 para facilitar la comparación de los mapas en los diferentes casos, y son de tipo hexagonal. La **Umatrix** (matriz unificada de distancias) es el método más popular para mostrar los resultados del SOM, estudiar cómo se localizan las agrupaciones (*clusters*) y ver si estas son fácilmente separables.

Se presentan en la figura 3.1 los mapas de activación de los índices para cada etapa, observando que los índices NN y RMSSD tienen un mapa muy similar en las etapas *20I*, *20F* y *0F*, es decir, estas variables están relacionadas. Además, se aprecia cierta relación entre las variables PLFn y RLFHF de las etapas *20I* y *20F*. Por otro lado, los mapas de un mismo índice varían según la etapa.

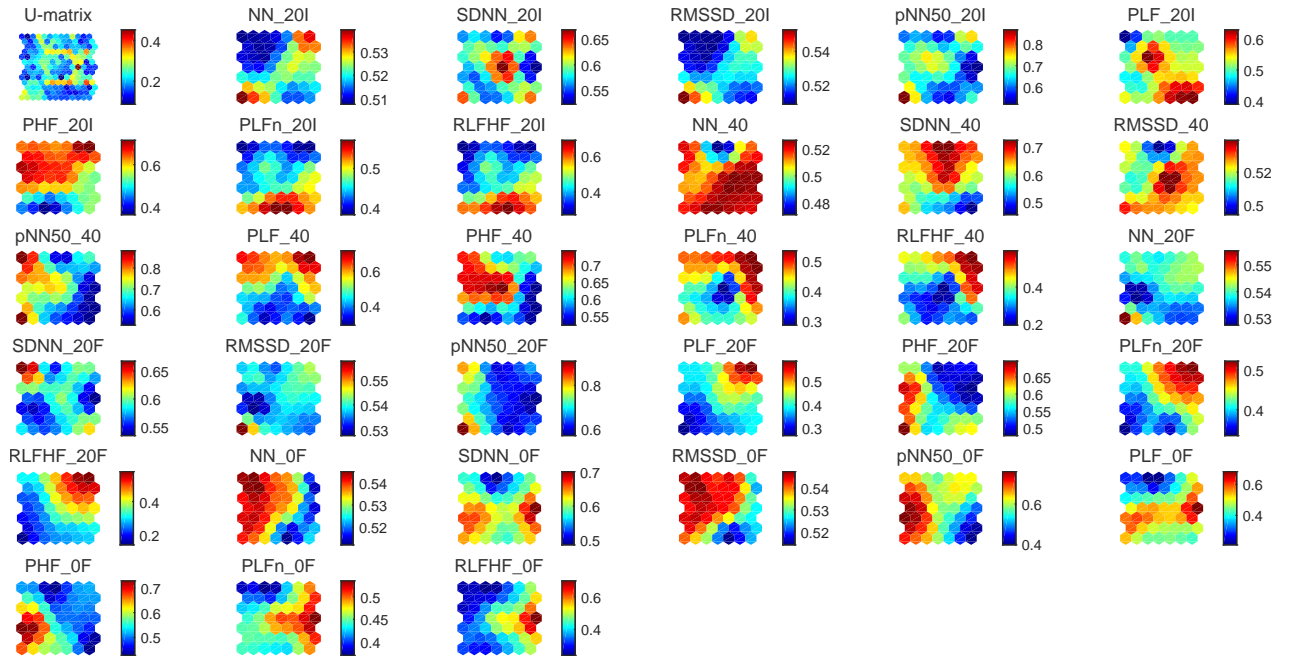


Fig. 3.1. Mapas de activación de los índices en cada etapa tras el entrenamiento.

En los mapas de activación de las etapas, recogidos en la figura 3.2, no se aprecia ninguna relación, pero se puede destacar que en el estado 40 y 0F se activan neuronas opuestas (es decir, cada mapa es una versión “espejada verticalmente” del otro). La conclusión más relevante que se puede extraer de dicha figura es que, aunque las presiones de las *etapas 0I-0F* y *20I-20F* son las mismas, no se observa semejanza entre sus mapas de activación. Por tanto, se demuestra que los factores *tiempo en inmersión* y *etapa descendente/ascendente* juegan un papel muy relevante en los índices medidos.




Fig. 3.2. Mapas de activación de las etapas tras el entrenamiento.

3.2. Análisis SOM usando los datos de los índices

3.2.1. Caso de estudio 1: Los índices como características

Las características son los 8 índices temporales y frecuenciales, donde las muestras son los datos de cada uno de los 17 sujetos asociadas a la etapa correspondiente. Los índices de calidad obtenidos tras el entrenamiento son: **Mean quantization error:** 0,0981 y **topographic error:** 0. El error medio es muy próximo a cero, por lo que indica un resultado aceptable de clasificación; sin embargo, aunque también interesa que el error topográfico sea lo más bajo posible, el hecho de que sea exactamente 0 no es garantía de una buena organización del mapa.

Teniendo en cuenta el código de colores recogido en la tabla 3.1, se observa en la figura 3.3 una dispersión a lo largo de todo el mapa de las 4 etapas, aunque la esquina inferior derecha está predominada por la *etapa 20I*. Debido a las dimensiones

de activación, también se destaca que la mayoría de las muestras de la *etapa 0F* se concentran en una región (por la parte superior central del mapa). Justo el comportamiento opuesto se atribuye a la *etapa 20I*, pues de las 17 muestras disponibles, 12 de ellas se encuentran dispersas por todo el mapa.

Etapa 20I	Etapa 40	Etapa 20F	Etapa 0F
Verde	Azul	Magenta	Amarillo

Tabla 3.1. Código de colores del SOM cuando se etiqueta por etapas.




Fig. 3.3. Umatrix con los clusters detectados (izquierda) y el mapa etiquetado (derecha) según las etapas usando los datos extraídos del ECG.

3.2.2. Caso de estudio 2: Las etapas como características

Las características son las 4 etapas, donde las muestras son las registradas de los 17 sujetos asociadas a los 8 índices. En esta ocasión, el código de colores es el que se muestra la tabla 3.2. Se está ante un caso complicado de detectar clusters (agrupaciones) fácilmente separables (figura 3.4). Aun así, se destaca que la presencia de la variable NN es prácticamente nula y lo hace compartiendo neuronas con el resto de índices.

Los índices de calidad obtenidos tras el entrenamiento son: **Mean quantization error**: 0,0720 y **topographic error**: 0,0956. Esta vez, si se comparan con el caso 1, ambos errores son bajos, y próximos a cero, así que las activaciones obtenidas representan una clasificación aceptable.

NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Rojo	Verde	Azul	Magenta	Amarillo	Cian	Naranja	Lila

Tabla 3.2. Código de colores del SOM cuando se etiqueta por índices.




Fig. 3.4. Umatrix con los clusters detectados (izquierda) y el mapa etiquetado (derecha) según los índices usando los datos extraídos del ECG.

3.2.3. Caso de estudio 3: Los índices como características, pero se etiquetan sujetos

Las características son los 8 índices de las 4 etapas, es decir, se tienen 32 características, etiquetándose así las muestras por sujetos, y se ha decidido reducir el tamaño del mapa a **6x6**, más que suficiente para la clasificación de los 17 sujetos que incluye este mapa. Si los sujetos presentasen el mismo comportamiento, se esperaría encontrar las neuronas de activación de la Umatrix concentradas en un mismo lugar. Atendiendo a la figura 3.5 y usando el código de colores de la tabla 3.3, se observa que los sujetos, de forma global, presentan variabilidad en la respuesta fisiológica del SNA. Sin embargo, se detectan tres clusters: uno en la esquina superior derecha, otro en la esquina superior izquierda y el más pequeño en la parte inferior. Se destaca que hay pocos sujetos que se localizan de forma totalmente aislada en el mapa, *sujetos 5 y 30*, lo que significa que las respuestas de sus sistemas nerviosos autónomos difieren notablemente de las del resto de sujetos.

Los índices de calidad obtenidos tras el entrenamiento son: **Mean quantization error:** 0,2278 y **topographic error:** 0,0588.

Sujeto 2	Sujeto 3	Sujeto 4	Sujeto 5	Sujeto 8
Rojo	Verde fosforito	Azul fuerte	Magenta	Amarillo
Sujeto 9	Sujeto 11	Sujeto 12	Sujeto 14	Sujeto 15
Cian	Naranja	Lila	Verde	Rosa claro
Sujeto 17	Sujeto 19	Sujeto 20	Sujeto 21	Sujeto 26
Marrón	Azul muy oscuro	Verde muy oscuro	Azul turquesa	Marrón claro
Sujeto 30	Sujeto 31			
Amarillo claro	Azul			

Tabla 3.3. Código de colores del SOM cuando se etiqueta por sujetos.




Fig. 3.5. Umatrix con los clusters detectados (izquierda) y el mapa etiquetado (derecha) según los sujetos usando los datos extraídos del ECG.

3.3. Análisis SOM usando los datos de los índices y las variables biofísicas

En este apartado se estudia cuál de las 16 variables biofísicas puede ser útil para clasificar a los sujetos, y ver si, junto a los índices de la *etapa 0I*, se consigue detectar clusters fácilmente. Previamente, se normalizan todos los datos mencionados entre el intervalo $[0,1]$ según la siguiente fórmula, de modo que se siga preservando la relación entre los datos nominales:

$$x_i = \frac{x_i - \min_i}{\max_i - \min_i}$$

Siendo x_i un valor de un atributo, y \max_i y \min_i los valores máximo y mínimo, respectivamente, de ese mismo atributo del conjunto de datos de entrenamiento

Se muestra en la figura 3.6 los mapas de activación para cada una de las variables biofísicas seleccionadas y se comprueba que solo hay cierta similitud entre los mapas de *Altura* y *Peso*. Como apunte, se observa que predomina un valor en el conjunto de datos de ciertos parámetros: 0 (azul) o 1 (rojo).

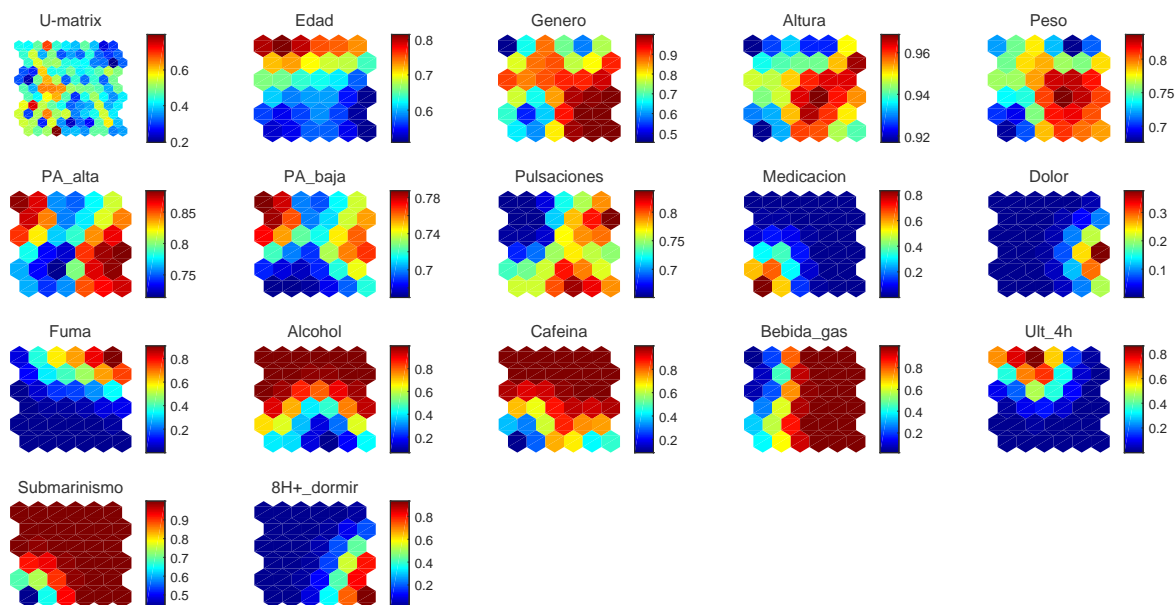


Fig. 3.6. Mapas de activación tras el entrenamiento de las variables biofísicas.

En el Anexo C se recogen los mapas de activación obtenidos al analizar los 8 índices de la *etapa 0I* junto a un solo parámetro biofísico, con la idea de detectar si esta última influye en la clasificación. Se destaca que la Umatrix de la variable *Presión Arterial baja* es igual al obtenido usando solo los índices, por lo que esta variable no es relevante. Las Umatrix de las variables *Altura* y *Peso* son bastante similares, ya que los *sujetos 2, 3 y 31* son los únicos que varían las neuronas de activación del mapa. Este comportamiento también se aprecia entre las variables *Presión Arterial alta* y *Dolor*, siendo ahora los *sujetos 11, 26 y 30* los implicados. La variable con Umatrix con más sujetos aislados es *Peso*, mientras que *Edad* y *Submarinismo* cuentan con la agrupación más numerosa (8 sujetos). Se observa que pertenecen a un cluster en la mayoría de las variables los *sujetos 8, 15 y 17* (en 15 variables); frente al *sujeto 5* cuya aparición aislada es la que predomina (en 10 variables). Por otro lado, el *sujeto 11* siempre activa regiones del mapa y pertenece a una agrupación del mismo, así como el *sujeto 21*, aunque este último no aparece en los mapas de activación de 7 variables. Otro comportamiento a tener en cuenta es que los *sujetos 9 y 14* pertenecen al mismo cluster, salvo cuando se hallan de forma aislada. Algo parecido sucede entre los *sujetos 2 y 30*.

Capítulo 4

Redes Neuronales Artificiales Multicapa

Se persigue predecir los valores de los índices de la *etapa 40* (variables de salida continuas) en función de un conjunto de valores de entrada correspondientes a un sujeto determinado (índices en la *etapa 01* y variables biofísicas). Debido al elevado número de variables disponibles que pueden jugar un papel importante y de forma conjunta en la respuesta fisiológica del sujeto en entornos hiperbáricos, como se ha mostrado en los capítulos anteriores, se presenta el entrenamiento de redes artificiales multicapa, utilizando además diferentes algoritmos de entrenamiento. Los parámetros de entrenamiento que varían en cada arquitectura son: número mínimo de ciclos de entrenamiento (*epochs*) y número de neuronas de la capa oculta, siendo el error cuadrático medio (MSE) objetivo 10^{-2} , un valor suficiente para tener una primera estimación adecuada. Para comparar la eficiencia de las redes se usa el MSE y el coeficiente de regresión medio (R) [32], escogiendo primero la arquitectura con menor MSE y con bajo número de neuronas en la capa oculta para evitar que las redes se sobre-ajusten por disponer de demasiados parámetros libres. Posteriormente, se estudia el valor R, interesando que sea lo más alto posible y positivo, pues, si es negativo, es signo de que la salida no sigue la tendencia de los datos.

4.1. Introducción

Se entrena una Red Neuronal Artificial de tipo Perceptrón Multicapa (MLP), junto a la regla de aprendizaje de *backpropagation*, para resolver un problema de **regresión**, aproximando por mínimos cuadrados. Sabiendo que existen relaciones no lineales entre las variables (resultados de la sección 2.3) se trabaja con tres capas: entrada, capa oculta (intermedia) y salida. Para evitar un proceso de entrenamiento lento debido a la regla de *backpropagation*, se complementa con técnicas de optimización usando uno de los siguientes **algoritmos de entrenamiento**:

- **Levenberg-Marquardt (LM)**: Algoritmo similar a los *quasi-Newton*, de segundo orden que es una alternativa a los métodos de gradiente conjugado para optimización rápida. El cálculo del error es menos complejo y costoso al trabajar con la matriz Jacobiana (en lugar de la Hessiana). Este método esquiva mejor los mínimos locales, pero la principal desventaja es que requiere un gran almacenamiento en memoria para las matrices Jacobianas.
- **Bayesian Regularization (BR)**: Modifica la función de coste (o error) utilizada (error cuadrático medio), con el objetivo de mejorar la capacidad de generalización del modelo. Además, esquiva los mínimos locales mejor que la técnica de descenso de gradiente. Por contra, requiere el cálculo de la matriz Hessiana, por lo que a menudo se suele combinar con el algoritmo de LM.
- **Descenso de gradiente con momento (GDM)**: Es el más simple y se considera de primer orden. Su principal inconveniente es el ajuste del parámetro encargado de controlar cuánto se desplazan los pesos en la red en la superficie del error (*tasa de aprendizaje*), influyendo sobre la velocidad de convergencia. El parámetro *constante de momentos* evita la inestabilidad que puede causar la variable anterior, pero su inclusión requiere el uso de memoria extra para almacenar el comportamiento del algoritmo en el paso anterior.
- **Resilient Backpropagation (RP)**: Este método combina el algoritmo de descenso de gradiente con métodos heurísticos. Utiliza solamente el signo de gradiente para determinar la dirección, acelerando así el ajuste del valor de los pesos al no basarse en las magnitudes de las derivadas. Tampoco exige grandes requisitos de almacenamiento de memoria [33].

4.1.1. Función de activación y tratamiento de los datos

Se escoge la **función de activación sigmoide** para las neuronas de la capa interna debido a que cubre el intervalo $[0,1]$, teniendo en cuenta que es continua y derivable.

Para escalar los valores de los índices de las *etapas 01 y 40*, así como el de los parámetros biofísicos, y que se siga preservando la relación entre ellos, se usa la función de normalización presentada en la sección 3.3.

En relación al conjunto de datos usado hasta el momento, se prescinde de las muestras de los *sujetos 2, 11, 21 y 26* por presentar valores no válidos (NaNs) en la *etapa 40*.

4.1.2. Función de coste y entrenamiento

Se opta por un entrenamiento supervisado, donde los pesos se inicializan de forma aleatoria para establecer un punto de partida no nulo. Para minimizar su influencia

sobre el resultado final, se repite una misma red (*pool*) 5 veces en cada arquitectura para evaluar el error promedio. La función de coste que se minimiza durante el entrenamiento de la red es el **error cuadrático medio**, y se mide sobre los valores de los índices de la *etapa 40* de un sujeto que no se ha usado en el proceso de entrenamiento. Es lo que se conoce como **validación cruzada**, más concretamente usando el método *leave-one-out*. Se escoge este método debido a las pocas muestras (sujetos) disponibles, de modo que realiza 13 iteraciones y en cada una de ellas se utiliza 12 subconjuntos para entrenar. La medida del error cometido es la media aritmética de los errores calculados en las distintas iteraciones.

4.2. MLPs para predecir los índices de la etapa 40 según los índices de la etapa 0I

La mejor red seleccionada para cada uno de los 8 índices de la *etapa 40* como salida, así como sus características, se exponen en la tabla 4.1, teniendo en cuenta las preferencias expuestas al inicio del apartado. Además, en el Anexo D se recogen las gráficas de cómo varía el MSE con el número de unidades en la capa oculta del MLP y el número de *epoch* realizadas para cada algoritmo. De modo que las conclusiones que se extraen son:

- Los valores de R sugieren que las redes entrenadas para los **índices de salida NN, SDNN y RMSSD** son aceptables. Para el resto de casos, este parámetro es bajo o incluso negativo, indicando que estas arquitecturas no son válidas para la predicción de dicho índice, aunque el valor de MSE sea muy bajo.
- Para los **índices de salida NN, SDNN y pNN50** se observa que el MSE disminuye al aumentar el número de neuronas en la capa oculta al usar el algoritmo de BR. Este comportamiento es indiferente para el número de ciclos. Sin embargo, no se distingue este hecho para los **índices de salida frecuenciales**, incluso para el caso del **índice PLFn** la tendencia del MSE para 50 y 100 epochs es creciente al aumentar el número de unidades en la capa oculta.
- El MSE disminuye al aumentar el número de ciclos de entrenamiento empleando el algoritmo de GMD en todos los casos. Además, para los **índices RMSSD y RLFHF** el MSE aumenta ligeramente al aumentar el número de neuronas en la capa intermedia.
- Al emplear el algoritmo RP, el MSE aumenta al aumentar el número de neuronas, excepto para los índices **PLF, PHF y PLFn**.
- Los errores medios de las distintas arquitecturas usando el algoritmo LM no siguen ninguna tendencia para alguna de las salidas, aunque destaca el valor

continuo de MSE obtenido para todas las arquitecturas, indistintamente del número de epochs empleado, para las variables **RMSSD** y **PLFn**.

Salida	Algoritmo	Arquitectura	Epochs	MSEeval	Reval	Time(s)
NN	RP	8/12/1	400	0,040	0,830	24,141
SDNN	LM	8/4/1	50	0,051	0,801	23,165
RMSSD	RP	8/8**/1	20	0,030	0,824	18,438
pNN50	RP	8/2**/1	20	0,083	0,520	20,186
PLF	BR	8/4/1	100	0,074	-0,961*	44,433
PHF	RP	8/2/1	20	0,087	0,501	19,450
PLFn	BR	8/2/1	100	0,077	-0,876*	84,637
RLFHF	BR	8/6/1	50	0,018	-0,622*	37,090

Tabla 4.1. Algoritmos y parámetros de calidad para los casos de menor MSE en los distintos MLP, siendo las salidas los índices de la etapa 40 individualmente y usando como parámetros de entrada los índices de la etapa 0I. En la columna *Arquitectura* se muestra el número de neuronas en cada capa.

*Arquitectura no recomendada por presentar un valor negativo de R.

**Arquitectura con un número de neuronas en la capa oculta bajo, aunque no sea el menor MSE conseguido.

4.3. MLPs para predecir los índices de la etapa 40 según los parámetros biofísicos

En las secciones anteriores se seleccionaron y analizaron 16 variables biofísicas. Sin embargo, debido a la presencia de valores no válidos, esta lista ha quedado reducida a 9 parámetros, siendo estos: *Edad, Altura, Peso, si toma medicación, si fuma, si toma alcohol, si consume cafeína, si ha tomado alguna de las anteriores sustancias en las últimas 4 horas y si el sujeto duerme más de 8 horas*. También queda excluida *si practica submarinismo* porque no aporta información sobre los índices de la *etapa 40*, según los resultados de nMI.

Siguiendo los mismos pasos que en el entrenamiento anterior, en la tabla 4.2 se recogen los parámetros de calidad de las arquitecturas con menor MSE para cada índice de salida, y en el Anexo D se recogen las gráficas con los valores medios de MSE para cada red, observando que:

- Los valores de R son mayoritariamente negativos y con un valor absoluto elevado, de modo que se concluye que los resultados no siguen la tendencia de los datos y que las variables biofísicas aportadas no son adecuadas para predecir los índices de la *etapa 40*.

- Para los **índices de salida PLF, PHF** se observa que el MSE disminuye al aumentar el número de neuronas en la capa oculta al usar el algoritmo de BR. Sin embargo, para los **índices de salida pNN50 y PLFn** el MSE aumenta al incrementar el tamaño de la capa oculta.
- El MSE disminuye al aumentar el número de ciclos de entrenamiento empleando el algoritmo de GMD, pero aumenta ligeramente conforme se eleva el número de neuronas en la capa intermedia en todos los casos.
- Al emplear el algoritmo RP, el MSE aumenta al aumentar el número de neuronas, salvo para los **índices SDNN y PLFn**.
- Los resultados usando el algoritmo LM son variados. En general, no siguen ninguna tendencia, aunque se observa que: para los **índices SDNN y PLFn** el valor MSE es prácticamente continuo, que aumenta irregularmente con el número de neuronas para los **índices PLF y RLFHF** y que se aprecia un cierto descenso con el número de neuronas para el **índice pNN50**.

Salida	Algoritmo	Arquitectura	Epochs	MSEeval	Reval	Time(s)
NN	LM	8/2/1	20	0,136	0,395	24,679
SDNN	BR	8/6/1	20	0,088	-0,894*	33,085
RMSSD	BR	8/4/1	50	0,085	-0,874*	49,560
pNN50	BR	8/2/1	100	0,109	-0,955*	38,620
PLF	GDM	8/2**/1	400	0,080	-0,625*	69,687
PHF	BR	8/8/1	400	0,098	-0,593*	47,930
PLFn	BR	8/8/1	400	0,078	-0,932*	65,637
RLFHF	BR	8/4**/1	400	0,020	-0,907*	39,094

Tabla 4.2. Algoritmos y parámetros de calidad para los casos de menor MSE en los distintos MLP, siendo las salidas los índices de la etapa 40 individualmente y usando como parámetros de entrada las variables biofísicas. En la columna *Arquitectura* se muestra el número de neuronas en cada capa.

*Arquitectura no recomendada por presentar un valor negativo de R.

**Arquitectura con un número de neuronas en la capa oculta bajo, aunque no sea el menor MSE conseguido.

4.4. MLPs para predecir los índices de la etapa 40 utilizando una combinación de entradas

Para conseguir un modelo general y que la red no quede sobre-entrenada es importante reducir el número de entradas. Con el objetivo de detectar variables que

tengan poca participación en la obtención del valor del índice deseado, se analizan los pesos de la capa de entrada de las arquitecturas escogidas en los apartados anteriores (Anexo D). El peso define la intensidad de la interacción: un valor positivo tiende a excitar la neurona, mientras que un valor negativo actúa de inhibidora, atenuando así su participación. De modo que se escogen aquellas variables a las que se les ha otorgado un mayor peso de entrada tras el entrenamiento. Esta información se recoge en la tabla 4.3. En los casos donde no se observa que unos pesos predominan o son muy bajos, no se especifica *entradas escogidas*.

Salida	Entradas escogidas	Observaciones
NN	SDNN, RMSSD, RLFHF, <i>Medic.</i> , <i>Fuma</i>	Variables con pesos negativos y/o muy próximos a cero: <i>Altura</i> , <i>Peso</i> , <i>Alcohol</i> , <i>Cafeína</i> , <i>Últ.4h</i> y <i>D.8h+</i> .
SDNN	SDNN, RMSSD, pNN50, PLF, PLFn, RLFHF	Los pesos de las variables PLF y PLFn son muy parecidos, y los pesos de las variables biofísicas alcanzan valores muy pequeños (10^{-2}).
RMSSD	-	Los pesos de los índices de la <i>etapa 0I</i> tienen un comportamiento similar. Los pesos de los parámetros biofísicos son muy pequeños (10^{-3}), afirmando, por ejemplo, que la variable <i>Alcohol</i> apenas influye.
pNN50	NN, RMSSD, pNN50, PHF	Los pesos otorgados a los parámetros biofísicos son valores muy pequeños (10^{-3}).
PLF	<i>Edad</i> , <i>Altura</i> , <i>Peso</i> , <i>Alcohol</i> , <i>Cafeína</i>	Caso contrario a los anteriores: los pesos asignados a las neuronas cuando se usan los índices de la <i>etapa 0I</i> como entrada son muy bajos (10^{-2}), y similares entre ellos; mientras que los valores cuando se usan los parámetros biofísicos son mucho más elevados.
PHF	NN, pNN50, PHF, PLFn, RLFHF	Los valores en el caso de los parámetros biofísicos son muy pequeños (10^{-2}), apreciando que para <i>Edad</i> , <i>Fuma</i> y <i>Cafeína</i> son prácticamente cero.
PLFn RLFHF	-	Tanto cuando se usan los índices de la <i>etapa 0I</i> como las variables biofísicas los valores de los pesos son muy pequeños (10^{-3}).

Tabla 4.3. Selección de las variables de entrada (índices de la etapa 0I y/o parámetros biofísicos) según el peso otorgado tras el entrenamiento para los 8 índices de la etapa 40 usados como salida.

Se vuelve a entrenar redes para estudiar el MSE con la nueva combinación de entrada, es decir, utilizando solo las variables que se muestran en *entradas escogidas*, aunque en esta ocasión se varía el número de neuronas en la capa oculta de 1 a 16 solamente. Se recogen las mejores arquitecturas en la tabla 4.4 junto a sus parámetros de calidad, teniendo en cuenta que para PLFn y RLFHF no se vuelve a repetir el proceso por el bajo valor de los pesos de las neuronas de entrada, ni para RMSSD por no variar el número de parámetros de entrada.

Salida	Algoritmo	Arquitectura	Epochs	MSEeval	Reval
NN	RP	5/4**/1	20	0,049	0,713
SDNN	RP	6/4/1	100	0,047	0,736
RMSSD	-	-	-	-	-
pNN50	RP	4/2**/1	20	0,078	0,577
PLF	BR	5/4/1	400	0,074	-0,671*
PHF	RP	5/2**/1	20	0,069	0,570
PLFn	-	-	-	-	-
RLFHF	-	-	-	-	-

Tabla 4.4. Algoritmos y parámetros de calidad para los casos de menor MSE en los distintos MLP, siendo las salidas los índices de la etapa 40 individualmente y usando como parámetros de entrada algunos índices de la etapa 0I y/0 algunas de las variables biofísicas. En la columna *Arquitectura* se muestra el número de neuronas en cada capa.

*Arquitectura no recomendada por presentar un valor negativo de R.

**Arquitectura con un número de neuronas en la capa oculta bajo, aunque no sea el menor MSE conseguido.

Capítulo 5

Discusión

En este trabajo se han utilizado, principalmente, los parámetros fisiológicos extraídos de la señal ECG de un grupo de sujetos, la cual fue grabada dentro de una cámara hiperbárica mientras se simulaban estados de inmersión a diferentes presiones atmosféricas. A lo largo del trabajo se ha ampliado el número de parámetros al incluir una serie de variables biofísicas, con el fin de mejorar la caracterización de la respuesta del SNA frente a los cambios de presión en la cámara.

En concreto, el principal objetivo de este estudio era ver si es posible el desarrollo de un modelo predictivo del comportamiento de los parámetros fisiológicos a una profundidad de 40 m, usando la información aportada por esos mismos parámetros registrados a nivel del mar junto a ciertas variables biofísicas. Poniendo el foco en los resultados de esas dos etapas (*etapa 0I* y *etapa 40*), se observan valores del coeficiente de correlación de Pearson, R^2 , bajos, simplemente destacando que existe mayor relación lineal entre los índices temporales que entre los índices frecuenciales, dándose resultados positivos entre los índices NN y RMSSD. Sin embargo, los valores nMI entre pares de datos son muy superiores, sobrepasando el 0,5 en la mayoría de los casos. Aparecen nuevas parejas relacionadas de forma significativa, como RMSSD y pNN50, así como los índices NN y pNN50 con ciertos índices frecuenciales. Sin embargo, ahora los índices NN y RMSSD de la *etapa 0I* con dichos índices de la *etapa 40* no sobrepasan el 0,75 del valor de nMI, cuando el coeficiente de correlación de Pearson era 0,873. Por lo general, los resultados que sobrepasan el umbral impuesto de estas dos medidas, R^2 y nMI, alcanzan un valor mayor en la primera medida. Este hecho puede estar afectado por el mapeo previo que se hace para poder calcular el valor de nMI, pues no admite valores NaN.

Repitiendo este mismo estudio, pero entre los índices de las *etapas 0I* y *40* con los parámetros biofísicos, la idea de que los pares estudiados sigan una relación lineal se descarta, salvo para la variable *Pulsaciones* con los índices NN y RMSSD,

así como el índice PLF de la *etapa 40* con las variables *Medicación* y *Cafeína*. En este caso, hay una mayor diversidad de valores de nMI, encontrando desde relaciones insignificantes, como es la variable *Cafeína* con los índices de la *etapa 40*, hasta pares altamente relacionados, como la *Presión Arterial alta y baja*. Se destaca que la variable *Submarinismo* con los índices de la *etapa 40* son totalmente independientes (valor de nMI igual a 0), así como que la variable *Pulsaciones* está altamente correlacionada con algunos índices de las *etapas 01 y 40* (valor de nMI igual a 1). Este efecto también puede ser fruto de la reducción del número de parejas de variables válidas tras el mapeo.

El método de Mutual Information dentro de la biomedicina se emplea mayoritariamente en el registro de imágenes, siendo una medida de garantía de la similitud entre ambas [34]. Sin embargo, en los últimos años está ganando terreno en el entorno de clasificación y aproximación, ya que se usa como método para selección de características. Concretamente, en el estudio realizado por Lan et al. [35] se usa para otorgar un peso a un nuevo biomarcador midiendo la relación entre las características de ese biomarcador y los diferentes tipos de cáncer de mama. La selección de características también es importante para reducir la complejidad computacional a la hora de predecir enfermedades por medio de la señal de EEG al reducir información, pues es una forma de encontrar de forma cuantitativa características relevantes o irrelevantes [36].

En este trabajo se ha escogido redes neuronales artificiales multicapa para la estimación deseada. Partiendo de las características de las mejores redes recogidas en las tablas 4.1, 4.2 y 4.4, se expone que:

- **Resultados para el índice de salida NN:** Mientras el MSE se mantiene para los mejores casos, el valor de R de la red escogida usando una combinación de entradas es ligeramente inferior al obtenido usando solamente los índices de la *etapa 01*, aunque posiblemente la primera red haya mejorado en generalización al reducir el número de entradas. Según los valores de nMI, se detectó una relación positiva con los índices de entrada NN y RMSSD y con el resto esos valores son cercanos al 0,75. Sin embargo, para las variables biofísicas de entrada escogidas, *Medic.* y *Fuma*, ese valor es muy bajo.
- **Resultados para el índice de salida SDNN:** En cuanto al comportamiento del MSE y R, siguen una tendencia parecida al anterior índice. Recordando que los índices de entrada seleccionados fueron: SDNN, RMSSD, pNN50, PLF, PLFn, RLFHF, se afirmó con el valor de nMI una relación positiva con el índice PHF de la *etapa 01* (no fue seleccionado por el bajo peso aportado a la neurona de entrada), aunque para el resto de los índices esos valores son muy cercanos a la referencia escogida para garantizar la relación.

Donde se observa con claridad la mejora de las características de la arquitectura del MLP escogida (MSE disminuye y R aumenta) al disminuir las variables de entrada es en los siguientes índices:

- **Resultados para el índice de salida pNN50:** se usan como variables de entrada solamente los índices: NN, RMSSD, pNN50, PHF. Se obtuvo valores de nMI que garantizan la relación con los índices RMSSD y pNN50 de la *etapa 0I*, y para el resto de entradas escogidas ese dato es muy próximo a 0,75. Por otro lado, el valor de R sigue siendo bajo como para considerar una buena estimación.
- **Resultados para el índice de salida PHF:** Se ha conseguido una arquitectura con R positiva, y bajo MSE, al escoger los índices de la *etapa 0I* más significativos como entradas (NN, pNN50, PHF, PLFn y RLFHF). Todos los valores de nMI para las entradas escogidas en el último entrenamiento rondan el 0,75, pero ninguno llega a valores que garanticen una alta correlación.

Curiosamente, las mejores arquitecturas escogidas al reducir el número de entradas para cada uno de estos 4 índices utilizan el mismo algoritmo de entrenamiento, el de *Resilient Backpropagation*, RP. Se destacan los buenos valores de MSE y R con la red escogida usando todos los índices de la *etapa 0I* para la variable de salida RMSSD, que también usa el algoritmo de entrenamiento anterior.

Escoger los parámetros biofísicos de entrada *Edad*, *Altura*, *Peso*, *Alcohol*, *Cafeína* para el índice de salida PLF debido al valor alto del peso otorgado a dichas neuronas no ha permitido entrenar una red con bajo MSE y un valor positivo de R. Este hecho puede quedar justificado con los valores de nMI entre PLF de la *etapa 40* y las variables biofísicas escogidas, ya que rondan solamente el 0,5 en la mayoría de ellas. Por otro lado, con el valor de nMI se afirma una relación de este índice con el índice NN de la *etapa 0I*.

Para los otros dos índices frecuenciales restantes, PLFn y RLFHF, tampoco se consigue entrenar una red con una mínima capacidad de estimación de estos valores.

Como apunte final a la base de datos utilizada, según el valor de nMI, las variables de *Presión Arterial*, tanto alta como baja, y *Pulsaciones* están correladas con los índices de la *etapa 40*, lo cual es esperable, pero el hecho de no haber podido recoger esta información adecuadamente, pues la mayoría de valores eran de tipo NaN, ha impedido su uso para el entrenamiento de las redes MLPs. Además, el contar con una base de datos con un número no muy elevado de sujetos hace que los resultados expuestos se puedan afirmar parcialmente.

Se han encontrado algunas investigaciones en el ámbito de la biomedicina donde se emplea el método de MI junto a métodos de machine learning para seleccionar el vector de características de entrada con el fin de, por ejemplo, ver si hay respuesta a la anestesia con isoflurano por medio del EEG [37] o distinguir de antemano pacientes que pueden llegar a sufrir delirio en la UCI por medio de algunas variables extraídas de la señal HRV [38]. Sin embargo, en este trabajo se plantea una combinación novedosa de estos dos métodos dentro del campo de la medicina al tratar de estimar el valor de ciertas variables, no una respuesta binaria.

El artículo [39], basado en la tesis [40], estudia la influencia del tiempo y la profundidad en la respuesta del SNA. Atendiendo a los resultados, confirma que el tiempo de inmersión y la profundidad hacen variar el comportamiento del SNA, tal y como se observó en los mapas auto-organizados de las etapas. También expone que los índices SDNN y RMSSD registran un aumento considerable respecto a la línea de base a 66, 99, 150 y 200 ft (20, 30, 45,7 y 61 m, aproximadamente), mientras que la variable PHF lo experimenta a 66 ft y 150 ft, y PLF solo a 150 ft. Recordando que los modelos de predicción de este trabajo se hacen con los valores registrados a 40 m, queda justificado el bajo peso asignado a los índices grabados en la línea de base en el MLP de la variable PLF. De modo que, empleando un método innovador en este trabajo del estudio de la señal HRV en la actividad de buceo mediante el uso de redes neuronales artificiales, se pueden contrastar los resultados obtenidos. En el artículo [41], cuyos datos se grabaron simulando una inmersión de 30 m en mar, y en la publicación [42] también se confirma la influencia del tiempo en el sistema cardiovascular, y este último añade que a 30 m solo se registran cambios en la rama parasimpática, mientras que a 60 m influyen ambas ramas del SNA.

Por otro lado, respecto a la clasificación de los sujetos, el *sujeto 5* se encuentra de forma aislada en el mapa de activación de la figura 3.5 y sigue esa misma tendencia en la mayoría de Umatrix obtenidas a partir de los índices de la *etapa 0I* junto a una variable biofísica. Se trata del único sujeto que indica que *siente dolor* antes de iniciar el registro y se localiza un valor ligeramente más alto del resto (0,7219 frente al siguiente dato mayor de 0,5803) del índice RLFHF de la *etapa 0F* normalizada según la línea de base. También es curioso el hecho de que los *sujetos 9 y 14* y los sujetos 2 y 30 pertenezcan, generalmente, al mismo cluster cuando no aparecen de forma aislada. La tendencia de estos 4 sujetos no es fácil de distinguir, ya que lo único destacado es el bajo valor del índice RLFHF de la *etapa 0I* para los *sujetos 9 y 14*. Finalmente, el hecho de que los mapas de activación de los parámetros biofísicos *Altura y Peso* sean muy similares se puede deber a que son datos con un abanico muy amplio de valores que, normalmente, no siguen ningún patrón.

Capítulo 6

Conclusiones y trabajo futuro

Se comenzó por un análisis sencillo estudiando la posible relación lineal entre pares de variables. A pesar de los pocos resultados positivos detectados, se destaca la importancia de los índices NN y RMSSD, ya que:

- Los índices NN y RMSSD de la *etapa 0I* se relacionan linealmente con esos mismos índices en las otras etapas.
- Los índices NN y RMSSD de las distintas etapas se relacionan linealmente con las *pulsaciones* de los sujetos.

Posteriormente, tras investigar sobre el método de *Mutual Information*, se pudo ver que ciertas variables frecuenciales también comparten información con el índice NN de la *etapa 0I*, por ejemplo el índice PLF de la *etapa 40*, con un valor de nMI de 0,785 frente al valor de R^2 de 0,177.

Se observa que hay pocos pares de variables con alto valor de nMI, por ello se decidió emplear modelos multivariable y, por tanto, ampliar el estudio al campo de las redes neuronales artificiales. En un primer momento, se elige la opción de normalizar según los valores de línea de base (*etapa 0I*) para evitar la influencia de la diferencia de valor de los datos, concluyendo que:

- El tiempo en inmersión y el hecho de estar en una etapa descendente o ascendente en el entorno hiperbárico afectan notablemente a los índices de actividad del SNA.
- Existe una alta variabilidad de la respuesta del SNA entre sujetos expuestos a un entorno hiperbárico.

Con la idea de detectar parámetros biofísicos poco influyentes, se analizan los mapas auto-organizados de los índices de la *etapa 0I* junto a una variable biofísica, adaptando el método de normalización, y se observa que:

- La forma de normalizar los datos modifica las Umatrix obtenidas.
- El número de variables que pueden influir en la respuesta al SNA a determinada profundidad es muy elevado, como muestran los diferentes mapas auto-organizados.

Para finalizar, la estimación de los índices del SNA a 40 m de profundidad realizada con las redes tipo MLP es bastante mejorable, ya que la base de datos actual no es lo suficientemente amplia. Aún así, se destaca el alto valor del coeficiente de regresión medio, junto a un bajo valor del error cuadrático medio, de las arquitecturas para predecir los índices NN y RMSSD, dando peso a las relaciones detectadas en el estudio con pares de variables. Sin embargo, no ha sido posible entrenar una red aceptable para los índices PLF, PLFn y RLFHF. De forma general, los parámetros biofísicos no aportan un gran peso a la predicción de los índices de la *etapa 40*.

En los próximos meses está previsto realizar nuevos registros que permitirán ampliar la base de datos, lo que ayudaría a mejorar notablemente los modelos de redes neuronales obtenidos para todos los índices. Como línea futura de trabajo, sería interesante comprobar si las redes neuronales artificiales entrenadas son capaces de aumentar la generalización y proporcionar mejores estimaciones de la respuesta del SNA en entornos hiperbáricos variables. Incluir registros en aguas abiertas y estudiar igualmente esos nuevos datos también es una línea futura interesante.

Bibliografía

- [1] P. K.-J. Jeong Heejeong, “Clinical applications of heart rate variability in neurological disorders,” *J Korean Neurol Assoc*, vol. 35, no. 1, pp. 1–7, 2017.
- [2] E. Ebrahimzadeh, M. Pooyan, and A. Bijar, “A novel approach to predict sudden cardiac death (scd) using nonlinear and time-frequency analyses from hrv signals,” *PloS one*, vol. 9, p. e81896, 02 2014.
- [3] Wikipedia contributors, “Mutual information — Wikipedia, the free encyclopedia,” 2018. [Online; accessed 6-November-2018].
- [4] D. Levett and I. Millar, “Bubble trouble: a review of diving physiology and disease,” *Postgraduate medical journal*, vol. 84, no. 997, pp. 571–578, 2008.
- [5] M. Halsey, “Effects of high pressure on the central nervous system,” *Physiological reviews*, vol. 62, no. 4, pp. 1341–1377, 1982.
- [6] E. P. Widmaier, H. Raff, and K. T. Strang, *Vander’s human physiology: the mechanisms of body function*. McGraw-Hill Higher Education, 2008.
- [7] M. Hagberg and H. Ornhagen, “Incidence and risk factors for symptoms of decompression sickness among male and female dive masters and instructors—a retrospective cohort study.,” 2003.
- [8] A. Pelliccia, R. Fagard, H. H. Bjørnstad, A. Anastassakis, E. Arbustini, D. Assanelli, A. Biffi, M. Borjesson, F. Carre, D. Corrado, *et al.*, “Recommendations for competitive sports participation in athletes with cardiovascular diseasea consensus document from the study group of sports cardiology of the working group of cardiac rehabilitation and exercise physiology and the working group of myocardial and pericardial diseases of the european society of cardiology,” *European heart journal*, vol. 26, no. 14, pp. 1422–1445, 2005.
- [9] A. Camm, M. Malik, J. Bigger, G. Breithardt, S. Cerutti, R. Cohen, P. Coumel, E. Fallen, H. Kennedy, R. Kleiger, *et al.*, “Heart rate variability: standards of measurement, physiological interpretation and clinical use. task force of the european society of cardiology and the north american society of pacing and electrophysiology,” *Circulation*, vol. 93, no. 5, pp. 1043–1065, 1996.

- [10] G. B. Moody, R. G. Mark, A. Zoccola, and S. Mantero, “Derivation of respiratory signals from multi-lead ecgs,” *Computers in cardiology*, vol. 12, no. 1985, pp. 113–116, 1985.
- [11] P. H. Charlton, D. A. Birrenkott, T. Bonnici, M. A. Pimentel, A. E. Johnson, J. Alastruey, L. Tarassenko, P. J. Watkinson, R. Beale, and D. A. Clifton, “Breathing rate estimation from the electrocardiogram and photoplethysmogram: A review,” *IEEE reviews in biomedical engineering*, vol. 99, pp. 1–17, 2017.
- [12] R. Bailón, L. Mainardi, M. Orini, L. Sörnmo, and P. Laguna, “Analysis of heart rate variability during exercise stress testing using respiratory information,” *Biomedical Signal Processing and Control*, vol. 5, no. 4, pp. 299–310, 2010.
- [13] A. Hernando, J. Lázaro, E. Gil, A. Arza, J. M. Garzón, R. López-Antón, C. de la Cámara, P. Laguna, J. Aguiló, and R. Bailón, “Inclusion of respiratory frequency information in heart rate variability analysis for stress assessment,” *IEEE journal of biomedical and health informatics*, vol. 20, no. 4, pp. 1016–1025, 2016.
- [14] V. Lund, J. Laine, T. Laitio, E. Kentala, J. Jalonen, and H. Scheinin, “Instantaneous beat-to-beat variability reflects vagal tone during hyperbaric hyperoxia.,” 2003.
- [15] V. Lund, E. Kentala, H. Scheinin, J. Klossner, H. Helenius, K. Sariola-Heinonen, and J. Jalonen, “Heart rate variability in healthy volunteers during normobaric and hyperbaric hyperoxia.,” *Acta physiologica Scandinavica*, vol. 167, no. 1, pp. 29–35, 1999.
- [16] E. Barbosa, J. M. García-Manso, J. M. Martín-González, S. Sarmiento, F. J. Calderón, and M. E. Da Silva-Grigoletto, “Effect of hyperbaric pressure during scuba diving on autonomic modulation of the cardiac response: application of the continuous wavelet transform to the analysis of heart rate variability,” *Military medicine*, vol. 175, no. 1, pp. 61–64, 2010.
- [17] V. Lund, E. Kentala, H. Scheinin, J. Klossner, K. Sariola-Heinonen, and J. Jalonen, “Hyperbaric oxygen increases parasympathetic activity in professional divers.,” *Acta physiologica Scandinavica*, vol. 170, no. 1, pp. 39–44, 2000.
- [18] K. Yamauchi, Y. Tsutsui, Y. Endo, S. Sagawa, F. Yamazaki, and K. Shiraki, “Sympathetic nervous and hemodynamic responses to lower body negative pressure in hyperbaria in men,” *American Journal of Physiology-Regulatory, Integrative and Comparative Physiology*, vol. 282, no. 1, pp. R38–R45, 2002.
- [19] D. R. Seals, D. G. Johnson, and R. F. Fregosi, “Hyperoxia lowers sympathetic activity at rest but not during exercise in humans,” *American Journal of*

Physiology-Regulatory, Integrative and Comparative Physiology, vol. 260, no. 5, pp. R873–R878, 1991.

- [20] H. Al Haddad, P. B. Laursen, D. Chollet, F. Lemaitre, S. Ahmaidi, and M. Buchheit, “Effect of cold or thermoneutral water immersion on post-exercise heart rate recovery and heart rate variability indices,” *Autonomic Neuroscience*, vol. 156, no. 1-2, pp. 111–116, 2010.
- [21] R. Perini and A. Veicsteinas, “Heart rate variability and autonomic activity at rest and during exercise in various physiological conditions,” *European journal of applied physiology*, vol. 90, no. 3-4, pp. 317–325, 2003.
- [22] J. Schipke and M. Pelzer, “Effect of immersion, submersion, and scuba diving on heart rate variability,” *British Journal of Sports Medicine*, vol. 35, no. 3, pp. 174–180, 2001.
- [23] F. Chouchou, V. Pichot, M. Garet, J.-C. Barthélémy, and F. Roche, “Dominance in cardiac parasympathetic activity during real recreational scuba diving,” *European journal of applied physiology*, vol. 106, no. 3, p. 345, 2009.
- [24] L. Ueno, M. Miyachi, T. Matsui, K. Takahashi, K. Yamazaki, K. Hayashi, S. Onodera, and T. Moritani, “Effect of aging on carotid artery stiffness and baroreflex sensitivity during head-out water immersion in man,” *Brazilian journal of medical and biological research*, vol. 38, no. 4, pp. 629–637, 2005.
- [25] A. Hernando, M. Pelaez, M. T. L. Albalade, M. Aiger, D. Izquierdo, A. Sanchez, M. I. Lopez-Jurado, J. I. Moura, J. Fidalgo, J. Lazaro, *et al.*, “Autonomic nervous system measurement in hyperbaric environments using ecg and ppg signals,” *IEEE Journal of Biomedical and Health Informatics*, 2018.
- [26] L. Batina, B. Gierlichs, E. Prouff, M. Rivain, F.-X. Standaert, and N. Veyrat-Charvillon, “Mutual information analysis: a comprehensive study,” *Journal of Cryptology*, vol. 24, no. 2, pp. 269–291, 2011.
- [27] M. Vu, “Lecture 2: Entropy and mutual information,” tech. rep.
- [28] Jose Delpiano, “Fast mutual information of two images or signals,” 2015.
- [29] Marcelo R. Ferreyra, “Correlación e información mutua,” 2008.
- [30] Laboratory of Computer and Information Science (CIS) of the Department of Computer Science and Engineering at the Helsinki University, “Som toolbox,” 2005.
- [31] M. L. Westerlund, “Classification with kohonen self-organizing maps,” *Soft Computing, Haskoli Islands*, 2005.

- [32] C. Vastrad *et al.*, “Performance analysis of neural network models for oxazolines and oxazoles derivatives descriptor dataset,” *arXiv preprint arXiv:1312.2853*, 2013.
- [33] M. Jiménez, “Redes neuronales y preprocesado de variables para modelos y sensores en bioingeniería,” *Ingeniería En Electrónica. Universidad Politécnica de Valencia*, 2012.
- [34] J. P. Pluim, J. A. Maintz, and M. A. Viergever, “Mutual-information-based registration of medical images: a survey,” *IEEE transactions on medical imaging*, vol. 22, no. 8, pp. 986–1004, 2003.
- [35] C. Lan, H. Peng, E. M. McGowan, G. Hutvagner, and J. Li, “An isomir expression panel based novel breast cancer classification approach using improved mutual information,” *BMC medical genomics*, vol. 11, no. 6, p. 118, 2018.
- [36] L. Fang, H. Zhao, P. Wang, M. Yu, J. Yan, W. Cheng, and P. Chen, “Feature selection method based on mutual information and class separability for dimension reduction in multidimensional time series for clinical data,” *Biomedical Signal Processing and Control*, vol. 21, pp. 82–89, 2015.
- [37] L. Huang, P. Yu, F. Ju, and J. Cheng, “Prediction of response to incision using the mutual information of electroencephalograms during anaesthesia,” *Medical engineering & physics*, vol. 25, no. 4, pp. 321–327, 2003.
- [38] J. Oh, D. Cho, J. Park, S. H. Na, J. Kim, J. Heo, C. S. Shin, J.-J. Kim, J. Y. Park, and B. Lee, “Prediction and early detection of delirium in the intensive care unit by using heart rate variability and machine learning,” *Physiological measurement*, vol. 39, no. 3, p. 035004, 2018.
- [39] Y. Noh, H. F. Posada-Quintero, Y. Bai, J. White, J. P. Florian, P. R. Brink, and K. H. Chon, “Effect of shallow and deep scuba dives on heart rate variability,” *Frontiers in physiology*, vol. 9, p. 110, 2018.
- [40] Y. Bai, *Evaluation of the Effects of Hyperbaric Dive Environments on the Autonomic Nervous System Using Principal Dynamic Mode Analysis*. PhD thesis, Worcester Polytechnic Institute, 2011.
- [41] M. Kozakiewicz, J. Slomko, K. Buszko, W. Sinkiewicz, J. J. Klawe, M. Tafil-Klawe, J. L. Newton, and P. Zalewski, “Acute biochemical, cardiovascular, and autonomic response to hyperbaric (4 atm) exposure in healthy subjects,” *Evidence-Based Complementary and Alternative Medicine*, vol. 2018, 2018.
- [42] S. Kujawski, J. Slomko, M. Zawadka-Kunikowska, M. Kozakiewicz, J. J. Klawe, M. Tafil-Klawe, and P. Zalewski, “Effects of hyperbaric exposure on the cardiovascular system. role of the autonomous nervous system,” *Polish Hyperbaric Research*, vol. 61, no. 4, pp. 33–42, 2017.

Lista de abreviaturas

0F	Etapa de ascenso a nivel del mar, 1 atm
0I	Etapa a nivel del mar, 1 atm
20F	Etapa de ascenso a 20m, 3 atm
20I	Etapa de descenso a 20m, 3 atm
40	Etapa de descenso a 40m, 5 atm
BMU	Best Matching Units
BR	algoritmo de entrenamiento de Bayesian Regularization
DS	Decompression Sickness
ECG	Electrocardiograma
EEG	Electroencefalograma
GDM	algoritmo de entrenamiento de Descenso de gradiente con momento
HF	High Frequency
HRV	Heart Rate Variability
LF	Low Frequency
LM	algoritmo de entrenamiento de Levenberg-Marquardt
MI	Mutual Information
MLP	Multilayer Perceptron
MSE	Error cuadrático medio
NaN	Not a Number
nMI	Normalized Mutual Information
NN	Valor mediano de los intervalos entre latidos consecutivos clasificados como Normales

PHF Potencia en la banda de alta frecuencia de la señal HRV

PLFn Potencia en la banda de baja frecuencia normalizada de la señal HRV

PLF Potencia en la banda de baja frecuencia de la señal HRV

pNN50 Número de pares de NN sucesivos que difieren en más de 50ms, dividido por el número total de intervalos NN

RLFHF Potencia en la banda de baja frecuencia normalizada de la señal HRV

RMSSD Raíz cuadrada de la media de los cuadrados de las diferencias sucesivas entre los intervalos NN adyacentes

RP algoritmo de entrenamiento de Resilient Backpropagation

R Coeficiente de correlación de Pearson

SDNN Rango intercuartílico de los intervalos NN, como una medida de dispersión estadística

SNA Sistema Nervioso Autónomo

SOM Self-Organizing Map

Índice de figuras

1.1. Detección del pulso cardiaco en una señal de ECG y medición del intervalo pico a pico (RR o NN) para extraer la señal de HRV [1]. . .	2
1.2. Señal HRV (izquierda) y su representación en forma de densidad espectral de potencial (derecha), indicando las bandas de frecuencia estudiadas, LF y HF [2].	2
2.1. Diferentes valores de entropía. Mutual information es la incertidumbre común en ambas variables, x e y [3].	11
3.1. Mapas de activación de los índices en cada etapa tras el entrenamiento.	18
3.2. Mapas de activación de las etapas tras el entrenamiento.	19
3.3. Umatrix con los clusters detectados (izquierda) y el mapa etiquetado (derecha) según las etapas usando los datos extraídos del ECG. . . .	20
3.4. Umatrix con los clusters detectados (izquierda) y el mapa etiquetado (derecha) según los índices usando los datos extraídos del ECG. . . .	21
3.5. Umatrix con los clusters detectados (izquierda) y el mapa etiquetado (derecha) según los sujetos usando los datos extraídos del ECG. . . .	22
3.6. Mapas de activación tras el entrenamiento de las variables biofísicas. .	23
C.1. Umatrix con los clusters detectados (izquierda) y el mapa etiquetado (derecha) según los sujetos usando los índices de la etapa 0I normalizados según la fórmula de la sección 3.3.	
C.2. Umatrix de los índices de la etapa 0I y la variable biofisica en cuestión, normalizados todos los datos según la fórmula de la sección 3.3 (I). .	
C.3. Umatrix de los índices de la etapa 0I y la variable biofisica en cuestión, normalizados todos los datos según la fórmula de la sección 3.3 (II). .	
C.4. Umatrix de los índices de la etapa 0I y la variable biofisica en cuestión, normalizados todos los datos según la fórmula de la sección 3.3 (III).	

- D.1. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice NN de la etapa 40. Entradas: índices de la etapa 0I.
- D.2. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice SDNN de la etapa 40. Entradas: índices de la etapa 0I.
- D.3. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice RMSSD de la etapa 40. Entradas: índices de la etapa 0I.
- D.4. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice pNN50 de la etapa 40. Entradas: índices de la etapa 0I.
- D.5. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PLF de la etapa 40. Entradas: índices de la etapa 0I.
- D.6. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PHF de la etapa 40. Entradas: índices de la etapa 0I.
- D.7. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PLFn de la etapa 40. Entradas: índices de la etapa 0I.
- D.8. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice RLFHF de la etapa 40. Entradas: índices de la etapa 0I.
- D.9. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice NN de la etapa 40. Entradas: variables biofísicas.
- D.10. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice SDNN de la etapa 40. Entradas: variables biofísicas.
- D.11. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice RMSSD de la etapa 40. Entradas: variables biofísicas.
- D.12. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice pNN50 de la etapa 40. Entradas: variables biofísicas.

- D.13.MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PLF de la etapa 40. Entradas: variables biofísicas.
- D.14.MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PHF de la etapa 40. Entradas: variables biofísicas.
- D.15.MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PLFn de la etapa 40. Entradas: variables biofísicas.
- D.16.MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice RLFHF de la etapa 40. Entradas: variables biofísicas.
- D.17.MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice NN de la etapa 40. Entradas: índices de la etapa 0I y/o variables biofísicas con peso dominantes. . .
- D.18.MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice SDNN de la etapa 40. Entradas: índices de la etapa 0I y/o variables biofísicas con peso dominantes.
- D.19.MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice pNN50 de la etapa 40. Entradas: índices de la etapa 0I y/o variables biofísicas con peso dominantes.
- D.20.MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PLF de la etapa 40. Entradas: índices de la etapa 0I y/o variables biofísicas con peso dominantes.
- D.21.MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PHF de la etapa 40. Entradas: índices de la etapa 0I y/o variables biofísicas con peso dominantes.
- D.22.Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice NN de la etapa 40. (a) MLP formado con 12 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 2 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.
- D.23.Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice SDNN de la etapa 40. (a) MLP formado con 4 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 6 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.

- D.24. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice RMSSD de la etapa 40. (a) MLP formado con 8 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 4 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.
- D.25. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice pNN50 de la etapa 40. (a) MLP formado con 2 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 2 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.
- D.26. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice PLF de la etapa 40. (a) MLP formado con 4 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 2 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.
- D.27. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice PHF de la etapa 40. (a) MLP formado con 2 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 8 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.
- D.28. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice PLFn de la etapa 40. (a) MLP formado con 2 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 8 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.
- D.29. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice RLFHF de la etapa 40. (a) MLP formado con 6 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 4 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.

Índice de tablas

2.1.	Valores de R^2 entre los índices del estado 0I y del estado 0I.	8
2.2.	Valores de R^2 entre los índices del estado 0I y del estado 40.	8
2.3.	Valores de R^2 entre los datos biofísicos y las variables del estado 0I. .	9
2.4.	Valores de R^2 entre los datos biofísicos y las variables del estado 40. .	9
2.5.	Valores de MI normalizados entre los índices del estado 0I y del estado 0I.	13
2.6.	Valores de MI normalizados entre los índices del estado 0I y del estado 40.	13
2.7.	Valores de MI normalizados entre los datos biofísicos y las variables del estado 0I.	15
2.8.	Valores de MI normalizados entre los datos biofísicos y las variables del estado 40.	15
3.1.	Código de colores del SOM cuando se etiqueta por etapas.	20
3.2.	Código de colores del SOM cuando se etiqueta por índices.	21
3.3.	Código de colores del SOM cuando se etiqueta por sujetos.	22
4.1.	Algoritmos y parámetros de calidad para los casos de menor MSE en los distintos MLP, siendo las salidas los índices de la etapa 40 individualmente y usando como parámetros de entrada los índices de la etapa 0I. En la columna <i>Arquitectura</i> se muestra el número de neuronas en cada capa.	28
4.2.	Algoritmos y parámetros de calidad para los casos de menor MSE en los distintos MLP, siendo las salidas los índices de la etapa 40 individualmente y usando como parámetros de entrada las variables biofísicas. En la columna <i>Arquitectura</i> se muestra el número de neuronas en cada capa.	29

4.3. Selección de las variables de entrada (índices de la etapa 0I y/o parámetros biofísicos) según el peso otorgado tras el entrenamiento para los 8 índices de la etapa 40 usados como salida.	30
4.4. Algoritmos y parámetros de calidad para los casos de menor MSE en los distintos MLP, siendo las salidas los índices de la etapa 40 individualmente y usando como parámetros de entrada algunos índices de la etapa 0I y/o algunas de las variables biofísicas. En la columna <i>Arquitectura</i> se muestra el número de neuronas en cada capa.	31
A.1. Valores de R^2 entre los índices del estado 0I y del estado 20I.	
A.2. Valores de R^2 entre los índices del estado 0I y del estado 20F.	
A.3. Valores de R^2 entre los índices del estado 0I y del estado 0F.	
A.4. Valores de R^2 entre los datos biofísicos y las variables del estado 20I.	
A.5. Valores de R^2 entre los datos biofísicos y las variables del estado 20F.	
A.6. Valores de R^2 entre los datos biofísicos y las variables del estado 0F. .	
B.1. Valores de MI normalizados entre los índices del estado 0I y del estado 20I.	
B.2. Valores de MI normalizados entre los índices del estado 0I y del estado 20F.	
B.3. Valores de MI normalizados entre los índices del estado 0I y del estado 0F.	
B.4. Valores de MI normalizados entre los datos biofísicos y las variables del estado 20I.	
B.5. Valores de MI normalizados entre los datos biofísicos y las variables del estado 20F.	
B.6. Valores de MI normalizados entre los datos biofísicos y las variables del estado 0F.	

Anexo A

Regresión lineal

A.1. Índices etapa 0I con resto de etapas

		Etapa 20I							
		NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Etapa 0I	NN	0,926	0,091	0,880	0,243	0,331	0,072	0,060	0,155
	SDNN	0,504	0,598	0,581	0,713	0,019	0,035	0,006	0,076
	RMSSD	0,918	0,104	0,881	0,255	0,310	0,072	0,057	0,150
	pNN50	0,632	0,432	0,669	0,777	0,010	0,028	0,063	0,207
	PLF	0,115	0,219	0,067	0,053	0,685	0,242	0,039	0,087
	PHF	0,008	0,396	0,020	0,520	0,133	0,489	0,049	0,091
	PLFn	0,096	0,063	0,111	0,316	0,044	0,092	0,226	0,373
	RLFHF	0,075	0,029	0,075	0,247	0,087	0,114	0,374	0,467

Tabla A.1. Valores de R^2 entre los índices del estado 0I y del estado 20I.

		Etapa 20F							
		NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Etapa 0I	NN	0,932	0,290	0,920	0,274	0,136	0,042	0,014	0,000
	SDNN	0,375	0,753	0,436	0,690	0,037	0,205	0,004	0,037
	RMSSD	0,933	0,303	0,927	0,294	0,146	0,029	0,021	0,000
	pNN50	0,490	0,616	0,548	0,760	0,000	0,176	0,056	0,001
	PLF	0,236	0,016	0,199	0,032	0,412	0,279	0,038	0,055
	PHF	0,024	0,221	0,008	0,285	0,179	0,752	0,052	0,016
	PLFn	0,027	0,132	0,042	0,200	0,009	0,257	0,281	0,177
	RLFHF	0,046	0,075	0,052	0,153	0,000	0,078	0,113	0,084

Tabla A.2. Valores de R^2 entre los índices del estado 0I y del estado 20F.

Etapa 0I	Etapa 0F							
	NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
	NN	0,805	0,447	0,828	0,224	0,047	0,027	0,002
	SDNN	0,139	0,589	0,215	0,478	0,072	0,235	0,004
	RMSSD	0,786	0,446	0,808	0,235	0,048	0,016	0,006
	pNN50	0,187	0,560	0,250	0,535	0,064	0,274	0,030
	PLF	0,244	0,024	0,156	0,034	0,439	0,195	0,068
	PHF	0,211	0,062	0,157	0,117	0,307	0,852	0,048
	PLFn	0,014	0,031	0,014	0,097	0,030	0,516	0,408
	RLFHF	0,000	0,017	0,001	0,082	0,045	0,217	0,253

Tabla A.3. Valores de R^2 entre los índices del estado 0I y del estado 0F.

A.2. Índices etapa 0I con variables biofísicas

	Etapa 20I							
	NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Edad	0,017	0,360	0,017	0,252	0,181	0,262	0,000	0,000
Género	0,240	0,0291	0,238	0,0260	0,090	0,126	0,021	0,000
Altura	0,275	0,035	0,300	0,077	0,056	0,003	0,082	0,010
Peso	0,241	0,019	0,256	0,097	0,054	0,035	0,057	0,023
PAalta	0,195	0,346	0,221	0,176	0,038	0,217	0,005	0,009
PAbaja	0,005	0,168	0,004	0,144	0,000	0,007	0,063	0,005
Pulsac.	0,831	0,139	0,737	0,409	0,841	0,006	0,410	0,631
Medic.	0,104	0,005	0,118	0,003	0,052	0,718	0,109	0,050
Dolor	0,444	0,205	0,452	0,149	0,010	0,002	0,003	0,020
Fuma	0,184	0,065	0,148	0,195	0,022	0,074	0,002	0,038
Alcohol	0,002	0,076	0,000	0,020	0,029	0,034	0,013	0,023
Cafeína	0,093	0,000	0,110	0,004	0,076	0,291	0,006	0,005
B. gas	0,008	0,164	0,015	0,282	0,029	0,165	0,345	0,239
Últ.4h	0,000	0,005	0,004	0,001	0,038	0,035	0,002	0,012
Submar.	0,010	0,003	0,014	0,025	0,026	0,013	0,052	0,019
D. 8h+	0,141	0,333	0,136	0,289	0,001	0,047	0,034	0,053

Tabla A.4. Valores de R^2 entre los datos biofísicos y las variables del estado 20I.

Etapa 20F								
	NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Edad	0,026	0,022	0,014	0,046	0,223	0,112	0,065	0,069
Género	0,125	0,023	0,118	0,001	0,166	0,043	0,008	0,000
Altura	0,105	0,046	0,109	0,092	0,001	0,001	0,015	0,016
Peso	0,027	0,031	0,026	0,036	0,044	0,000	0,021	0,006
PAalta	0,088	0,038	0,080	0,075	0,253	0,181	0,039	0,001
PAbaja	0,004	0,047	0,006	0,083	0,001	0,049	0,027	0,012
Pulsac.	0,804	0,663	0,769	0,451	0,005	0,657	0,104	0,116
Medic.	0,161	0,001	0,144	0,011	0,478	0,078	0,096	0,023
Dolor	0,432	0,081	0,450	0,140	0,020	0,018	0,000	0,009
Fuma	0,001	0,010	0,001	0,017	0,078	0,000	0,133	0,092
Alcohol	0,032	0,196	0,046	0,038	0,025	0,085	0,014	0,002
Cafeína	0,245	0,059	0,236	0,095	0,204	0,005	0,149	0,023
B. gas	0,000	0,000	0,001	0,174	0,000	0,192	0,184	0,192
Últ.4h	0,000	0,019	0,002	0,006	0,104	0,085	0,299	0,116
Submar.	0,017	0,017	0,018	0,037	0,002	0,014	0,017	0,001
D. 8h+	0,009	0,001	0,011	0,020	0,001	0,000	0,009	0,005

Tabla A.5. Valores de R^2 entre los datos biofísicos y las variables del estado 20F.

Etapa 0F								
	NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Edad	0,047	0,207	0,013	0,056	0,447	0,109	0,326	0,221
Género	0,424	0,015	0,422	0,052	0,171	0,123	0,001	0,020
Altura	0,353	0,045	0,423	0,172	0,007	0,017	0,002	0,013
Peso	0,259	0,000	0,298	0,104	0,120	0,012	0,107	0,046
PAalta	0,353	0,018	0,373	0,366	0,206	0,434	0,003	0,018
PAbaja	0,001	0,181	0,005	0,038	0,025	0,000	0,038	0,093
Pulsac.	0,906	0,399	0,951	0,734	0,015	0,568	0,001	0,164
Medic.	0,545	0,003	0,489	0,064	0,433	0,115	0,052	0,003
Dolor	0,241	0,781	0,280	0,024	0,164	0,0209	0,122	0,374
Fuma	0,074	0,114	0,048	0,044	0,166	0,111	0,167	0,121
Alcohol	0,013	0,021	0,003	0,031	0,049	0,032	0,011	0,047
Cafeína	0,380	0,000	0,370	0,061	0,211	0,025	0,089	0,006
B. gas	0,004	0,070	0,008	0,120	0,187	0,138	0,045	0,013
Últ.4h	0,018	0,011	0,027	0,010	0,081	0,153	0,492	0,241
Submar.	0,012	0,001	0,021	0,006	0,002	0,018	0,036	0,002
D. 8h+	0,022	0,352	0,043	0,004	0,339	0,000	0,193	0,288

Tabla A.6. Valores de R^2 entre los datos biofísicos y las variables del estado 0F.

Anexo B

Mutual Information

B.1. Índices etapa 0I con resto de etapas

Etapa 0I	Etapa 20I							
	NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
	NN	0,883	0,723	0,685	0,735	0,670	0,640	0,518
	SDNN	0,656	0,695	0,603	0,708	0,580	0,538	0,611
	RMSSD	0,872	0,711	0,723	0,723	0,657	0,625	0,626
	pNN50	0,665	0,703	0,765	0,815	0,595	0,636	0,721
	PLF	0,703	0,690	0,703	0,703	0,707	0,656	0,656
	PHF	0,670	0,657	0,722	0,670	0,596	0,615	0,566
	PLFn	0,665	0,652	0,665	0,665	0,595	0,728	0,669
	RLFHF	0,562	0,546	0,619	0,562	0,473	0,416	0,678
								0,554

Tabla B.1. Valores de MI normalizados entre los índices del estado 0I y del estado 20I.

Etapa 0I	Etapa 20F							
	NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
	NN	0,799	0,733	0,904	0,667	0,613	0,658	0,684
	SDNN	0,685	0,640	0,619	0,669	0,606	0,550	0,581
	RMSSD	0,720	0,722	0,776	0,703	0,599	0,646	0,623
	pNN50	0,688	0,643	0,625	0,671	0,561	0,559	0,538
	PLF	0,731	0,667	0,602	0,743	0,713	0,637	0,663
	PHF	0,686	0,594	0,623	0,670	0,685	0,679	0,586
	PLFn	0,566	0,623	0,603	0,552	0,536	0,588	0,667
	RLFHF	0,475	0,645	0,459	0,569	0,515	0,496	0,529
								0,415

Tabla B.2. Valores de MI normalizados entre los índices del estado 0I y del estado 20F.

		Etapa 0F							
Etapa 0I		NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
	NN	0,809	0,566	0,819	0,663	0,586	0,746	0,677	0,590
	SDNN	0,574	0,617	0,660	0,662	0,574	0,600	0,701	0,440
	RMSSD	0,774	0,583	0,843	0,625	0,542	0,708	0,639	0,543
	pNN50	0,672	0,764	0,691	0,696	0,619	0,641	0,766	0,561
	PLF	0,801	0,571	0,758	0,874	0,757	0,776	0,726	0,733
	PHF	0,867	0,534	0,800	0,752	0,619	0,877	0,654	0,498
	PLFn	0,658	0,540	0,677	0,682	0,542	0,626	0,753	0,607
	RLFHF	0,620	0,597	0,705	0,647	0,491	0,583	0,663	0,557

Tabla B.3. Valores de MI normalizados entre los índices del estado 0I y del estado 0F.

B.2. Índices etapa 0I con variables biofísicas

		Etapa 20I							
		NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Edad		0,673	0,661	0,673	0,723	0,709	0,568	0,626	0,500
Género		0,312	0,240	0,418	0,276	0,394	0,208	0,406	0,228
Altura		0,773	0,661	0,723	0,673	0,604	0,625	0,678	0,582
Peso		0,721	0,659	0,790	0,671	0,760	0,566	0,676	0,580
PAalta		0,714	0,815	0,714	0,624	0,795	0,675	0,795	0,575
PAbaja		0,460	0,575	0,623	0,318	0,586	0,604	0,586	0,378
Puls.		0,910	0,910	0,910	0,910	0,910	0,810	0,910	0,768
Medic.		0,224	0,171	0,369	0,222	0,386	0,411	0,181	0,103
Dolor		0,365	0,226	0,369	0,224	0,176	0,249	0,181	0,199
Fuma		0,241	0,300	0,331	0,456	0,385	0,126	0,249	0,207
Alcohol		0,181	0,514	0,218	0,278	0,127	0,309	0,427	0,129
Cafeína		0,234	0,194	0,343	0,193	0,318	0,288	0,312	0,106
B. gas		0,418	0,210	0,414	0,403	0,078	0,217	0,315	0,446
Últ.4h		0,181	0,281	0,181	0,278	0,127	0,356	0,150	0,063
Submar.		0,220	0,222	0,220	0,168	0,177	0,124	0,371	0,201
D. 8h+		0,343	0,346	0,302	0,452	0,131	0,388	0,199	0,106

Tabla B.4. Valores de MI normalizados entre los datos biofísicos y las variables del estado 20I.

Etapa 20F								
	NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Edad	0,614	0,667	0,552	0,695	0,486	0,587	0,712	0,590
Género	0,199	0,234	0,131	0,305	0,301	0,361	0,242	0,289
Altura	0,661	0,709	0,649	0,691	0,641	0,684	0,708	0,537
Peso	0,614	0,667	0,651	0,713	0,538	0,587	0,566	0,498
PAalta	0,713	0,821	0,795	0,638	0,713	0,608	0,713	0,595
PAbaja	0,598	0,598	0,685	0,630	0,598	0,595	0,717	0,571
Puls.	0,744	0,821	0,845	0,660	0,797	0,714	0,744	0,460
Medic.	0,230	0,224	0,176	0,375	0,414	0,234	0,230	0,444
Dolor	0,371	0,220	0,377	0,361	0,147	0,142	0,228	0,266
Fuma	0,326	0,379	0,127	0,320	0,115	0,232	0,288	0,263
Alcohol	0,203	0,217	0,137	0,286	0,068	0,226	0,293	0,197
Cafeína	0,196	0,154	0,235	0,509	0,310	0,121	0,232	0,334
B. gas	0,292	0,277	0,347	0,196	0,209	0,259	0,327	0,244
Últ.4h	0,136	0,246	0,235	0,262	0,164	0,434	0,521	0,270
Submar.	0,175	0,168	0,143	0,222	0,186	0,119	0,141	0,135
D. 8h+	0,521	0,189	0,392	0,262	0,368	0,219	0,365	0,404

Tabla B.5. Valores de MI normalizados entre los datos biofísicos y las variables del estado 20F.

Etapa 0F								
	NN	SDNN	RMSSD	pNN50	PLF	PHF	PLFn	RLFHF
Edad	0,696	0,566	0,712	0,663	0,844	0,667	0,787	0,590
Género	0,501	0,136	0,361	0,492	0,303	0,501	0,293	0,159
Altura	0,687	0,646	0,704	0,710	0,575	0,657	0,723	0,516
Peso	0,716	0,445	0,733	0,739	0,542	0,626	0,753	0,543
PAalta	1,000	0,547	0,763	0,763	0,763	0,746	0,763	0,726
PAbaja	0,726	0,307	0,607	0,607	0,607	0,529	0,607	0,744
Puls.	0,910	0,768	0,910	0,910	0,810	0,558	0,910	0,910
Medic.	0,406	0,118	0,388	0,401	0,427	0,431	0,175	0,263
Dolor	0,239	0,482	0,388	0,175	0,247	0,139	0,400	0,257
Fuma	0,164	0,281	0,230	0,237	0,340	0,150	0,244	0,179
Alcohol	0,155	0,133	0,312	0,218	0,232	0,181	0,255	0,081
Cafeína	0,290	0,143	0,346	0,359	0,303	0,275	0,238	0,349
B. gas	0,257	0,361	0,284	0,257	0,168	0,371	0,436	0,084
Últ.4h	0,330	0,253	0,414	0,218	0,189	0,448	0,530	0,405
Submar.	0,140	0,085	0,222	0,230	0,146	0,115	0,136	0,193
D. 8h+	0,365	0,279	0,346	0,195	0,507	0,151	0,282	0,399

Tabla B.6. Valores de MI normalizados entre los datos biofísicos y las variables del estado 0F.

Anexo C

Resultados SOM variables biofísicas






Fig. C.1. Umatrix con los clusters detectados (izquierda) y el mapa etiquetado (derecha) según los sujetos usando los índices de la etapa 0I normalizados según la fórmula de la sección 3.3.



(a) Índices junto a edad



(b) Índices junto a género



(c) Índices junto a altura



(d) Índices junto a peso



(e) Índices junto a presión arterial alta



(f) Índices junto a presión arterial baja


Fig. C.2. Umatrix de los índices de la etapa 0I y la variable biofísica en cuestión, normalizados todos los datos según la fórmula de la sección 3.3 (I).




(a) Índices junto a pulsaciones



(b) Índices junto a si toma medicación




(c) Índices junto a si tiene dolor



(d) Índices junto a si fuma



(e) Índices junto a si toma alcohol




(f) Índices junto a si toma cafeína

Fig. C.3. Umatrix de los índices de la etapa 0I y la variable biofísica en cuestión, normalizados todos los datos según la fórmula de la sección 3.3 (II).




(a) Índices junto a si toma bebidas con gas



(b) Índices junto a consumo en las últimas 4 horas



(c) Índices junto a si practica submarinismo



(d) Índices junto a si duerme 8 horas o más

Fig. C.4. Umatrix de los índices de la etapa 0I y la variable biofísica en cuestión, normalizados todos los datos según la fórmula de la sección 3.3 (III).

Anexo D

Resultados MLP


D.1. Error medio de cada arquitectura

Se apoya en la toolbox *Neural Network* de Matlab para el entrenamiento de las distintas arquitecturas, haciendo uso de las siguientes funciones:


- *fitnet* para crear la red con el número de neuronas en la capa oculta y el método de entrenamiento seleccionado.
- *net.layers1.transferFcn = 'logsig'* para escoger la función sigmoide.
- *net.divideParam.trainRatio = 1* ya que se pasa directamente el set de datos de entrenamiento.
- *net.trainParam.goal = 1e-2* es el error cuadrado máximo promedio.

A continuación, se exponen las gráficas del MSE medio de las distintas arquitecturas entrenadas con cada algoritmo para cada uno de los 8 índices de la etapa 40 como salida, variando las variables de entrada utilizadas.


Índices de la etapa 0I como datos de entrada




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.1. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice NN de la etapa 40. Entradas: índices de la etapa 0I.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.2. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice SDNN de la etapa 40. Entradas: índices de la etapa 0I.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.3. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice RMSSD de la etapa 40. Entradas: índices de la etapa 0I.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.4. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice pNN50 de la etapa 40. Entradas: índices de la etapa 0I.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.5. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PLF de la etapa 40. Entradas: índices de la etapa 0I.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.6. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PHF de la etapa 40. Entradas: índices de la etapa 0I.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.7. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PLF_n de la etapa 40. Entradas: índices de la etapa 0I.




(a) LM



(b) BR




(c) GDM




(d) RP

Fig. D.8. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice RLFHF de la etapa 40. Entradas: índices de la etapa 0I.


Variables biofísicas como datos de entrada




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.9. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice NN de la etapa 40. Entradas: variables biofísicas.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.10. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice SDNN de la etapa 40. Entradas: variables biofísicas.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.11. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice RMSSD de la etapa 40. Entradas: variables biofísicas.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.12. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice pNN50 de la etapa 40. Entradas: variables biofísicas.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.13. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PLF de la etapa 40. Entradas: variables biofísicas.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.14. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PHF de la etapa 40. Entradas: variables biofísicas.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.15. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PLF_n de la etapa 40. Entradas: variables biofísicas.




(a) LM



(b) BR




(c) GDM




(d) RP

Fig. D.16. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice RLFHF de la etapa 40. Entradas: variables biofísicas.


Índices de la etapa 0I y parámetros biofísicos seleccionados como datos de entrada




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.17. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice NN de la etapa 40. Entradas: índices de la etapa 0I y/o variables biofísicas con peso dominantes.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.18. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice SDNN de la etapa 40. Entradas: índices de la etapa 0I y/o variables biofísicas con peso dominantes.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.19. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice pNN50 de la etapa 40. Entradas: índices de la etapa 0I y/o variables biofísicas con peso dominantes.




(a) LM



(b) BR




(c) GDM




(d) RP


Fig. D.20. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PLF de la etapa 40. Entradas: índices de la etapa 0I y/o variables biofísicas con peso dominantes.




(a) LM



(b) BR




(c) GDM




(d) RP

Fig. D.21. MSE de los distintos algoritmos variando el número de unidades ocultas y el número de epochs. Salida: índice PHF de la etapa 40. Entradas: índices de la etapa 0I y/o variables biofísicas con peso dominantes.

D.2. Pesos de las neuronas de entrada de las arquitecturas seleccionadas




(a) Entrada: Índices etapa 0I




(b) Entrada: Parámetros biofísicos

Fig. D.22. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice NN de la etapa 40. (a) MLP formado con 12 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 2 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.




(a) Entrada: Índices etapa 0I




(b) Entrada: Parámetros biofísicos

Fig. D.23. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice SDNN de la etapa 40. (a) MLP formado con 4 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 6 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.




(a) Entrada: Índices etapa 0I




(b) Entrada: Parámetros biofísicos

Fig. D.24. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice RMSSD de la etapa 40. (a) MLP formado con 8 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 4 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.




(a) Entrada: Índices etapa 0I




(b) Entrada: Parámetros biofísicos

Fig. D.25. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice pNN50 de la etapa 40. (a) MLP formado con 2 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 2 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.




(a) Entrada: Índices etapa 0I




(b) Entrada: Parámetros biofísicos

Fig. D.26. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice PLF de la etapa 40. (a) MLP formado con 4 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 2 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.




(a) Entrada: Índices etapa 0I




(b) Entrada: Parámetros biofísicos

Fig. D.27. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice PHF de la etapa 40. (a) MLP formado con 2 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 8 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.




(a) Entrada: Índices etapa 0I




(b) Entrada: Parámetros biofísicos

Fig. D.28. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice PLFn de la etapa 40. (a) MLP formado con 2 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 8 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.



(a) Entrada: Índices etapa 0I



(b) Entrada: Parámetros biofísicos

Fig. D.29. Pesos de la capa de entrada de la arquitectura del MLP, siendo la salida el índice RLFHF de la etapa 40. (a) MLP formado con 6 neuronas en la capa interna, siendo las entradas los índices de la etapa 0I. (b) MLP formado con 4 neuronas en la capa interna, siendo las entradas los parámetros biofísicos.

